

4
2ej



UNIVERSIDAD NACIONAL AUTONOMA DE MEXICO

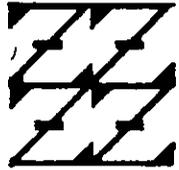
FACULTAD DE ESTUDIOS SUPERIORES
ZARAGOZA

EL USO DE MICROCONTROLADORES PROGRAMABLES, EN EL CONTROL Y ADQUISICION DE DATOS COMO ALTERNATIVA EN EL MODELADO DE PROCESOS QUIMICOS, EMPLEANDO PARA SU PROGRAMACION PARADIGMAS DE REDES NEURONALES.

T E S I S

QUE PARA OBTENER EL TITULO DE:
INGENIERO QUIMICO
P R E S E N T A N
JUAN CARLOS FLORES ACEVEDO
PEDRO MALDONADO ENCIZO

UNAM
FES
ZARAGOZA



LO HUBIERON OJJE
DE NUESTRA DEPLECION

ASESOR: ING. EDUARDO VAZQUEZ ZAMORA

MEXICO, D. F.

1999

274922

TESIS CON
FALLA DE OR. EN



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



UNIVERSIDAD NACIONAL DE
MÉXICO
AVENIDA DE
MÉXICO

**JEFATURA DE LA CARRERA
DE INGENIERIA QUIMICA**

OFICIO: FESZ/JCIQ/005/99

ASUNTO: Asignación de Jurado

**C. JUAN CARLOS FLORES ACEVEDO y
PEDRO MALDONADO ENCIZO
Presente**

En respuesta a su solicitud de asignación de jurado para el Examen Profesional, le comunico que la Jefatura a mi cargo ha propuesto la siguiente designación:

Presidente: I.Q. Alejandro Rogel Ramírez
Vocal: I.Q. Eduardo Vázquez Zamora
Secretario: I.Q. José Antonio Zamora Plata
Suplente: I.Q. Gabriel Cruz Zepeda
Suplente: I.Q. Genaro Altamirano García

Atentamente
"POR MI RAZA HABLARA EL ESPIRITU"
México, D.F., 25 de Enero de 1999

EL JEFE DE LA CARRERA

I.Q. ARTURO E. MÉNDEZ GUTIÉRREZ

Irm

A mis padres, abuelos, familiares y amigos

JUAN CARLOS FLORES ACEVEDO

Agustín Encizo Cano (†) y Guadalupe Galicia Alonso (†); porque gracias a ustedes logre alcanzar mi meta y porque de ustedes aprendí que la vida es un constante sacrificio, pero con muchas recompensas, y espero que donde quiera que estén compartan conmigo este logro.

Graciela Encizo Galicia; Como un tributo al gran sacrificio que has hecho desde el momento en que me diste la vida, por los desvelos y las penas que te pude causar, este trabajo esta dedicado totalmente a ti ;Gracias mama!.

Alma Delia Maldonado Encizo; por todo el apoyo que me brindas día con día y que espero seguir teniendo.

Eduardo Vázquez Zamora; por ser un gran maestro, en toda la extensión de la palabra ya que gracias a usted he aprendido muchas cosas muy valiosas, gracias por ser mi amigo.

Juan Carlos Flores Acevedo; por tu apoyo incondicional y por la gran amistad que nos une ;gracias amigo!.

A todos mis amigos gracias por estar siempre cuando me hacen falta.

MALDONADO ENCIZO PEDRO

INDICE

| | |
|---|-----------|
| RESUMEN. | 4 |
| 1. -INTRODUCCIÓN. | 5 |
| 2.-GENERALIDADES. | 8 |
| 2.1.- CONTROL DE PROCESOS | 8 |
| 2.1.1 - Aspectos que Determinan el Control de Procesos | 9 |
| 2.1.2 - Criterios de Realización para el Control de Procesos. | 12 |
| 2.2 -SISTEMAS DE ADQUISICIÓN DE DATOS. Conceptos Fundamentales. | 12 |
| 2.3.-MICROCONTROLADORES. Conceptos Básicos. | 14 |
| 2.4 -REDES NEURONALES. | 17 |
| 2.4.1.- Neuronas Biológicas y Artificiales. | 17 |
| 2.4.2.- Componentes de un Nodo. | 21 |
| 2.4.3.- Topología. | 23 |
| 2.4.4 - Aprendizaje en las Redes Neuronales. | 25 |
| 2.4.5.- Propagación Hacia Atrás. | 27 |
| 3.-DESCRIPCIÓN DEL MODELADO UTILIZANDO REDES NEURONALES. | 33 |

| | |
|---|-----------|
| 3.1.-MODELADO DEL PROCESO UTILIZANDO REDES NEURONALES. | 33 |
| 3.2.-MODELADO Y CONTROL UTILIZANDO REDES NEURONALES. | 34 |
| 3.3.-METODOS DE CARACTERIZACIÓN. | 35 |
| 3.3.1.- Caracterización de Procesos con Redes Neuronales | 35 |
| 3.3.2.- Fase Experimental | 36 |
| 3.3.3.- Adquisición de Datos. | 36 |
| 3.3.4.- Procesamiento de Datos. | 37 |
| 3.3.5.- Selección del Modelo. | 37 |
| 3.3.6.- Estimación de los Parámetros y Validación del Modelo. | 38 |
| 4.-DESARROLLO EXPERIMENTAL. | 40 |
| 4.1.-CARACTERÍSTICAS DEL MODELO. | 40 |
| 4.2.-CARACTERÍSTICAS DEL SOFTWARE. | 43 |
| 4.3.-CARACTERÍSTICAS DEL SISTEMA DE ADQUISICION DE DATOS. | 44 |
| 4.4.-MODELADO DINAMICO DEL SISTEMA. | 45 |
| 4.5.-METODOLOGÍA. | 51 |

| | |
|---|-----------|
| 4.5.1.-Adquisición de Datos | 51 |
| 4.5.2.-Procesamiento de Datos | 52 |
| 4.5.3.-Entrenamiento y Validación del Modelo | 52 |
| 4.5.4.-Elección del Modelo | 53 |
| 5.-RESULTADOS. | 54 |
| 5.1.-ANÁLISIS DE RESULTADOS. | 76 |
| 6.-CONCLUSIONES. | 81 |
| 7.-BIBLIOGRAFIA. | 83 |
| A.1.-APENDICE A (MÉTODOS DE ENTRENAMIENTO) | 86 |
| A.2.-APENDICE B (VENTAJAS Y DESVENTAJAS DE LAS REDES NEURONALES) | 89 |

RESUMEN

Este trabajo es una investigación cuyo objetivo es el uso de microcontroladores para el control y adquisición de datos como una alternativa para el modelado de procesos químicos.

Se programo un microcontrolador con una red neuronal lo suficientemente pequeña y eficiente, de forma tal que fuese capaz de correr en la limitada memoria del microcontrolador, lo que nos permite contar con un dispositivo de bajo costo que combina la flexibilidad del microcontrolador con la capacidad de un control robusto y la posibilidad de adaptar técnicas avanzadas de control.

Dicha red, o mejor dicho redes (ya que como se vera a lo largo del trabajo el proceso de selección requiere la evaluación de varias de estas redes) fueron entrenadas usando los datos recopilados por los sensores situados en un equipo de laboratorio. Posteriormente se procedió a la selección de la red que mejor cumpliera con los objetivos planteados, y que se resumen en tratar de obtener un bajo porcentaje de error.

A lo largo de todo el trabajo se intentó alcanzar un alto grado de generalización de forma tal que sea posible aplicar estos sistemas de control (basados en paradigmas de redes neuronales) a cualquier tipo de proceso químico.

1.- INTRODUCCIÓN.

El obtener un buen modelo de proceso es un trabajo difícil que consume mucho tiempo, pero que es esencial ya que este modelado es utilizado directamente en la fase de diseño del sistema de control.

Modelar un proceso químico es un intento de explicar la relación existente entre las variables de entrada y salida del proceso, y existen dos métodos utilizados para la construcción de dicho modelo.

El primer método desarrolla el modelo a partir de principios básicos fundamentales como son las leyes de conservación de la energía, masa y momentum. Los modelos obtenidos de esta forma son llamados modelos fenomenológicos y son el resultado del conocimiento previo de los fenómenos físicos y químicos que se llevan a cabo durante el proceso. Sin embargo estos modelos son demasiado complicados y para resolverlos es necesario hacer diversas suposiciones pertinentes que simplifiquen el problema.

El segundo método, llamado "método de caja negra", desarrolla el modelo a partir de datos experimentales de la planta, estos modelos tienen una sustentación estadística –no paramétrica - (Pottman and Senburg, 1992) o están basados en redes neuronales. Sin embargo los métodos estadísticos tienden a ser muy complicados y su precisión disminuye a medida que el problema crece.

Como consecuencia, en los últimos años se ha renovado el interés por los modelos basados en redes neuronales, debido a su estructura simple y a su habilidad para resolver problemas complicados. Su flexibilidad hace posible su aplicación en diversas ramas de la ingeniería química, tales como la rectificación de datos (Kajarla

et al)[9], la detección de fallas (Hoskins y Himmelblau)[6], el modelado de procesos (Bhat y McAvoy)[2], y el control de procesos usando redes neuronales como modelos de proceso (Saint-Donant et al)[19].

Por otro lado, el procesamiento de señales empleando redes neuronales, no ha sido utilizado en la ingeniería química, a pesar de que los ingenieros eléctricos y electrónicos han llevado a cabo diversas investigaciones en este campo.

Este documento trata de definir las principales características y métodos que deben emplearse para controlar un proceso en ingeniería química usando un microcontrolador para su control en tiempo real.

Se intenta programar a estos microcontroladores con un paradigma de redes neuronales, pequeño y eficiente que sea capaz de ejecutar dicho programa en la limitada memoria del microcontrolador, lo que permitirá contar con un dispositivo de bajo costo que combine la flexibilidad de un microcontrolador con la capacidad de un control robusto y que sea capaz de adaptar técnicas avanzadas de control.

Esta red será entrenada usando los datos recopilados por los sensores situados en un equipo de laboratorio, y será capaz de simular desde el comportamiento de un controlador de tipo proporcional, hasta un controlador directo que observe una respuesta opuesta del sistema.

Por otro lado, debido a la flexibilidad inherente de ambos sistemas, este tipo de control puede ser ajustado dependiendo de los requerimientos del proceso, sistema o equipo.

Finalmente se buscara generalizar el modelo del sistema de control basado en paradigmas de redes neuronales para que sea posible aplicarlo a cualquier tipo de proceso químico.

2.- GENERALIDADES.

2.1.- CONTROL DE PROCESOS

Los sistemas de control de procesos fueron creados para involucrar un sistema manejado por el equipo de control y sus operadores. Los procesos se analizan basándose en la utilización que tengan, desde su implementación hasta para conocer sus costos reales.

El equipo de control de procesos comprende los mecanismos de instrumentación del proceso, los controladores del proceso (basados en unidades de computo), elementos de comunicación para el sistema de interconexión e integración, y los elementos finales de control. El papel del equipo de control de procesos es el de respaldar e implementar las diferentes funciones del control de procesos tales como la regulación, el control de encendido y apagado y la protección y supervisión del proceso.

La selección de este equipo esta basado en un análisis funcional del proceso completo. El proceso en su totalidad se puede dividir en unidades de proceso básicas y controladores, los cuales están diseñados para implementar las funciones de cada unidad básica. Los controladores se implementan en cada uno de los sistemas funcionales para cada una de las funciones específicas del proceso y el equipo de comunicación se instala para mandar los datos regulatorios del proceso entre los controladores.

Las reglas generales de generación de señales, la adquisición de datos y el procesamiento y comunicación de los mismos, la ejecución de comandos y las acciones del proceso están gobernadas por la información procesada. El

funcionamiento de los sistemas de control de procesos sin embargo depende de la efectividad de la información procesada en los instrumentos del mismo, sus controladores e interconexiones, los mecanismos de entrada y salida y la coordinación entre ellos.

Un sistema de control se puede representar de acuerdo a un diagrama simple como el de la figura. 1

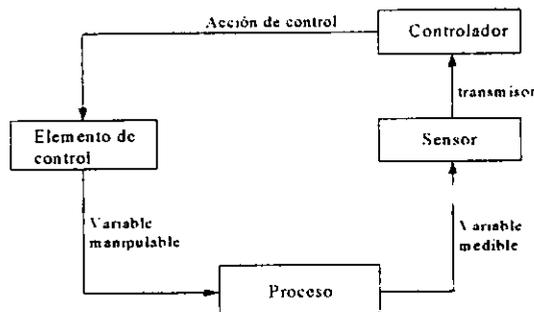


Figura 1.- Diagrama de bloques de un sistema de control simple

2.1.1.-Aspectos que Determinan el Control de Procesos

Un proceso se define como un conjunto de operaciones que realizan una o varias transformaciones físicas y/o químicas. Estos pueden incluir un proceso de producción, transporte de materia y energía, transmisión y procesamiento de información utilizada para la producción y procesamiento de bienes materiales, información y/o energía.

El proceso puede ser un equipo, una operación unitaria, una sección de la planta o la planta completa y que puede ser controlado y forma parte de un conjunto de producción, o son funciones del proceso ejecutadas en y por medio del equipo de proceso. Las características de un proceso usualmente se miden mediante cantidades o condiciones, definidas como variables de proceso. El control de estas variables de proceso se realiza por medio del sistema de control.

El proceso se encuentra situado en el ambiente de producción y puede ser afectado por los siguientes aspectos: humanos, tiempo-espacio, materiales-materias primas, energéticos, socioeconómicos, de manejo de información y medioambientales. Estos aspectos se interrelacionan en una forma complicada.

- 1) Los aspectos humanos en la mayor de las veces determinan el modo del control de procesos. Proporcionan el número de operadores, su trabajo, el respaldo educacional y calificaciones, y las responsabilidades del control del proceso dependen del tipo de proceso en particular y el sistema de control aplicado. Los aspectos humanos parecen ser los factores más influyentes en el funcionamiento apropiado y la productividad total del proceso.
- 2) Los aspectos tiempo-espacio determinan el carácter del tipo de proceso, muestran cinco características principales del proceso: velocidad (lento/rápido), espacio (concentrado/distribuido), continuidad (continuo/discreto), periodicidad (cíclico/aperiódico), y determinación (determinístico/estocástico). Los aspectos de tiempo-espacio influyen en la complejidad, automatización y sensibilidad de un proceso en particular.
- 3) Los aspectos materiales-materias primas muestran los cuatro tipos de manejo de materiales de proceso; fluidos de proceso, piezas nuevas, partes

simples y procesos para hojas y textiles. Los aspectos materiales y materias primas influyen en el tipo de variables de proceso, sensibilidad del mismo y el tipo y extensión del control del proceso.

- 4) Los aspectos energéticos determinan las categorías de procesos principales: Procesos de generación de energía (reactor químico), procesos de transformación de energía (planta hidroeléctrica) y procesos donde la energía se proporciona a partir de materiales procesados (maquinas y herramientas). Los aspectos energéticos son prominentes en el cálculo de la eficiencia de producción del proceso y su afectación, así como el tipo y extensión del control del proceso aplicado.
- 5) Los aspectos socioeconómicos determinan la adaptación de la producción. Consecuentemente, los principales tipos de procesos desarrollados que pueden ocurrir son la compra de equipo nuevo para procesos nuevos, el aumento de la capacidad de producción existente ó sencillamente el reemplazo de esta. Todos los estimados se basan en el análisis de costos futuros o beneficios esperados.
- 6) Los aspectos de información determinan la selección de la instrumentación del proceso y el equipo de procesamiento de datos.
- 7) Los aspectos ambientales determinan las medidas a favor de la protección ambiental.

Los sistemas de control en la industria se caracterizan por sus constantes cambios en los criterios de realización debido a que los procesos son en su mayoría altamente

no-lineales y muy difíciles de modelar, y a que las dinámicas del mercado demandan cambios en las estrategias de operación.

2.1.2.-Criterios de Realización para el Control de Procesos.

El sistema de control podrá ajustar las variables manipulables del proceso para satisfacer uno ó más de los siguientes criterios de realización prácticos.

- **Económico.-** Estos se pueden asociar con cualquier variable de proceso en los objetivos dictados para la optimización o la minimización dinámica en la función de costos de operación.
- **Seguridad y Medio Ambiente.-** Algunas variables de proceso no deben de violar barreras especificadas por razones de seguridad del personal ó del equipo, o a causa de regulaciones ambientales.
- **Equipo.-** El sistema de control no debe operar con limitaciones físicas de las salidas del sistema dentro del equipo.
- **Calidad del producto.-** Se deben satisfacer las especificaciones del consumidor ó del producto.

2.2.-SISTEMAS DE ADQUISICIÓN DE DATOS.

Un sistema de adquisición de datos y control basado en computadoras personales permite lo siguiente:

1. Medir variables físicas tales como temperatura, presión, flujo, etc.

2. Alimentar la información a la computadora.
3. Analizar los datos con ayuda de programas.
4. Proveer una respuesta apropiada de control para que influya en el proceso.

Es necesario considerar tanto la adquisición de la información de los ingenieros y operadores (fuera de línea y en tiempo real) como la suministrada por los sensores colocados en el equipo.

Con respecto a los tres primeros puntos son particularmente útiles las interfases gráficas basadas en diagramas y esquemáticos de la planta. Asimismo son válidas las consideraciones sobre el interés de la utilización de estructuras como los cuadros, redes semánticas, y la orientación al objeto, que permiten establecer de forma natural las conexiones entre los elementos de una determinada planta ó proceso. Otro aspecto de interés es la representación explícita del tiempo.

El problema de adquisición de conocimiento a partir de la medición con sensores puede contemplarse también como un problema de aprendizaje con o sin asistencia de los operadores. En el último de los casos podría plantearse que el sistema mediante aprendizaje inductivo, adquiriera reglas que le permitan distinguir entre un estado y otro del proceso. La generalización de estas reglas podría llevar a la formación de un nivel superior de descripción que generara las propias reglas de operación del proceso

2.2.1.-Conceptos Fundamentales.

Para implementar un sistema de adquisición de datos, primero es necesario delinear los objetivos de diseño, esto (como en cualquier otro proyecto). Es necesario romper

la aplicación en pequeños bloques que puedan entenderse y donde cada bloque representa una función particular. Esta metodología hace que al diseñar el proyecto este sea más simple. Durante la etapa del diseño, hay un punto importante que hay que recordar y es la de expansión del sistema.

El siguiente paso del diseño del proyecto es adicionar más detalle a cada subsistema representado por un bloque en particular, es necesario considerar varias restricciones operacionales y de medio ambiente, como ejemplo: medio agresivo industrial o en un laboratorio, el acondicionamiento de la señal y el aislamiento de las entradas, el desarrollo o la compra de software específico para control y adquisición de datos, distancia entre las computadoras y el resto del sistema. etc.

Siguiendo los anteriores criterios, se puede desarrollar y entender claramente la aplicación, una vez que la definición esta completa.

2.3.-MICROCONTROLADORES.

En los 60's, los dispositivos electromecánicos eran lo más novedoso en lo que a control se refiere. Estos dispositivos comúnmente conocidos como relevadores, se utilizaron por la mayoría para controlar los procesos de manufactura de tipo secuencial y maquinas automáticas. Muchos de estos relevadores se utilizaron en la industria del transporte, más específicamente, en la industria automotriz.

Estos relevadores, instalados en paneles y cabinas de control, usaban cientos de cables en sus interconexiones para efectuar el control. El desempeño de un relevador era seguro, como dispositivo separado. Pero las aplicaciones comunes, requerían de 300 a 500 o más relevadores, y la eficiencia y mantenimiento asociados se convertía en un verdadero reto.

Por otro lado, mientras un solo relevador era barato, el costo de un panel instalado era muy grande. El costo total incluyendo partes, alambrado e instalación podía variar de 30 a 50 dls por relevador. Aunado a este problema, los constantes cambios en el sistema, requerían también cambios en el panel de control y esto significaba un recableado y por lo tanto más costos e inconvenientes.

Por lo tanto debido a que se necesitaban sistemas que no presentasen grandes problemas ni costos surgió a finales de los 60's el primer controlador programable, que fue desarrollado como respuesta específica a las necesidades de los mayores constructores de autos en E. U. Estos primeros controladores o Controladores Lógicos Programables (PLC), representaban el primer sistema que:

- 1) Podía usarse dentro de la planta.
- 2) Podía cambiar su lógica de control sin un extensivo recableado ó cambio de sus componentes.
- 3) Era fácil de diagnosticar y reparar si ocurrían problemas.

2.3.1.-Conceptos básicos.

Todos los controladores programables están constituidos por los bloques funcionales básicos mostrados en la figura 2.

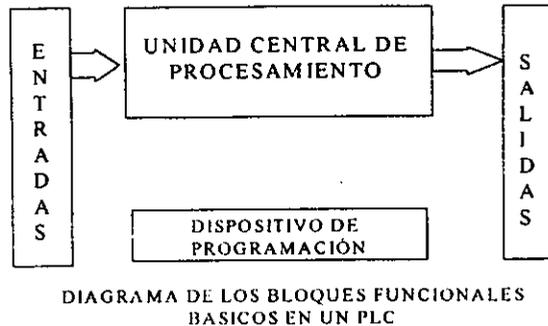


Figura 2.- Bloques funcionales básicos

Examinando cada uno de los bloques se puede entender la forma en que se relacionan con el sistema de control.

Primero, el CPU es el corazón (ó al menos el cerebro) del sistema. Y consiste de un microprocesador.

El controlador además cuenta con memoria lógica para el almacenamiento de la lógica de control, memoria variable ó de almacenamiento para usar los datos que cambian como función del programa de control y una fuente de energía que suministra la corriente eléctrica necesaria para el funcionamiento del procesador y la memoria.

Después viene el bloque de entrada/salida (I/O) que son los brazos, piernas, ojos y oídos del sistema. Los dispositivos de entrada pueden ser botones, fotosensores, sensores de posición, termocoples, etc. Y en los dispositivos de salida se tienen alarmas, motores, solenoides, impresoras, etc.

Existen tres características básicas que ayudan a clasificar a un dispositivo industrial de control como controlador programable.

- 1) Su operación interna básica es resolver la lógica de control, desde el principio de la memoria hasta un punto de paro especificado, que puede ser el fin de la memoria o el programa. Una vez que se ha alcanzado el fin, la operación empieza otra vez desde el principio de la memoria. Este proceso continúa desde el momento en que se suministra energía eléctrica hasta que se remueve la misma.
- 2) Cuenta con una lógica de programación.
- 3) Esta diseñado para un ambiente industrial. Este ambiente incluye altas temperaturas (0 a 60 °C), humedad extrema, vibración, polvo, etc.

2.4.-REDES NEURONALES.

Las redes neuronales son básicamente métodos de estimación multivariable no-lineal, no-paramétrica, que debido a su masivo paralelismo pueden procesar la información y dar soluciones casi simultáneamente. Son entrenadas ("aprenden") a través de mostrarles ejemplos y los resultados esperados, por lo que son una buena herramienta en problemas del tipo "reconocimiento de patrones".

Usualmente se emplean para aproximar la función $y = f(x)$, donde la forma de la función "f" se desconoce. Tomando en cuenta este punto de vista, surge la pregunta obvia ¿Porque usar este particular método de aproximación si existen muchos otros métodos estadísticos que son bastante usados?. En resumen la respuesta es que las

redes neuronales son aproximadores de funciones (cualquiera), que típicamente trabajan mucho mejor en aplicaciones prácticas que los tradicionales métodos de aproximación de funciones (polinomiales).

En los últimos años se ha renovado el interés en los modelos basados en redes neuronales debido a su estructura simple y a su rápido desempeño computacional. Su flexibilidad las hace apropiadas para un variado tipo de aplicaciones en la Ingeniería Química que van desde la rectificación de datos hasta el control de procesos.

Existen tres razones principales para el desarrollo de las redes neuronales en el campo de la Ingeniería Química.

- Primero, los recientes avances en tecnología computacional y procesamiento paralelo han hecho el uso de las redes neuronales más factible, desde el punto de vista económico, que en el pasado.
- Segundo, ya que las redes neuronales están compuestas de redes funcionales básicas no lineales, tienen la habilidad de convertirse en buenos modelos de proceso a partir de datos ejemplo. Y requieren poco o casi ningún conocimiento “a priori” de la tarea a desempeñar, como lo demuestran las diversas áreas en las que se investiga la aplicación de estas y que solo en ingeniería química van desde la rectificación de datos [9] hasta el modelado y control de procesos [2], [19].
- Tercero, las redes neuronales tienen el potencial para resolver ciertos tipos de problemas complejos que no serían manejados satisfactoriamente por métodos más tradicionales, entre los que se

encuentra la representación de inteligencia artificial, la cual debe ser formal y no se puede tener sentido común ó pensamiento intuitivo, lo que se suma a su limitada habilidad para hacer analogías y manejar información poco precisa ó confusa.

2.4.1.- Neuronas Biológicas y Artificiales.

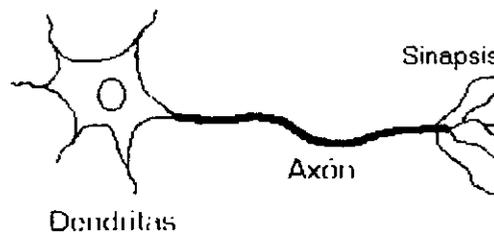


Figura 3. Neurona biológica

Las neuronas biológicas como la mostrada en la figura 3, están constituidas por el cuerpo de la célula mas un axón y muchas dendritas. El axón es una protuberancia que transmite los estímulos de la neurona y la conecta con otras neuronas. Las dendritas son protuberancias que proveen de una gran área superficial, facilitando la conexión con los axones de otras neuronas.

Una neurona no hace nada a menos que la influencia colectiva de todos los estímulos que llegan a ella, provenientes de otras neuronas, alcancen un valor umbral. Siempre que este valor es alcanzado, la neurona produce una fuerte respuesta en forma de pulso, a lo que se conoce como activación.

Existe evidencia que señala que el aprendizaje tiene lugar en la vecindad de las sinapsis y tiene algo que ver con el grado en el que las sinapsis transmiten el pulso de activación a la siguiente neurona.

Las redes neuronales están constituidas por neuronas simuladas (a las que se les conoce simplemente como neuronas ó nodos), como la que muestra la siguiente figura.

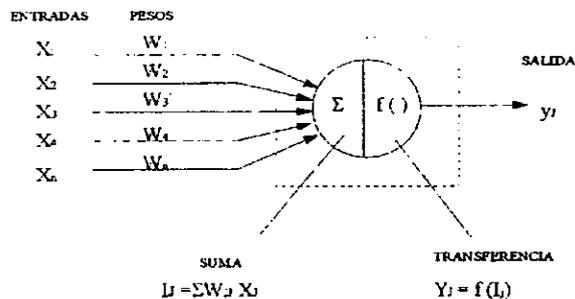


Figura 4 componentes de un nodo

Una neurona simulada puede ser vista como un nodo conectado a otros nodos por medio de enlaces, que corresponden a las conexiones axón-sinapsis-dendrita.

Típicamente el nodo toma un conjunto de entradas, las suma, resuelve una función, por lo general lineal y transmite la respuesta a través de las conexiones ó enlaces, las cuales están asociadas a un peso (w) y, como una sinapsis, este peso determina la fuerza con la que el nodo influencia a otros.

Los pesos que conectan a una neurona con otra sirven como parámetros ajustables, los cuales se fijan mediante un método de “entrenamiento”, esto es, son estimados utilizando parte de los datos.

La neurona es entonces, tan solo un predictor variable y la red una combinación no lineal de predictores variables (Figura 5)

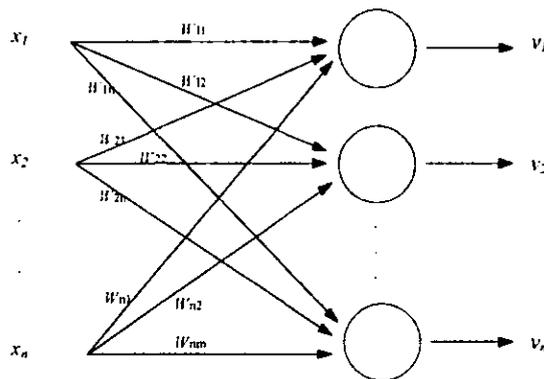


Figura 5.-Combinación con otros nodos

2.4.2.- Componentes de un Nodo.

En la sección anterior se explicó a grandes rasgos el funcionamiento de un nodo, por lo que a continuación se procederá a explicar cada uno de sus componentes.

- Entradas y salidas. Tomando en cuenta el j -ésimo nodo, el primer elemento es el vector de entradas x con $x_1, x_2, x_3, \dots, x_n$ componentes. El nodo manipula estas entradas o actividades para producir una respuesta o salida. Y debido a la estructura de la red esta salida puede formar parte del vector de entradas de otro nodo.

- Pesos. Como se menciona en la sección anterior, cada conexión entre nodos tiene asociado un factor de peso (w) ó simplemente peso, el cual, puede tener un efecto de inhibición ó excitación, ya que cada peso es multiplicado por su entrada correspondiente. Por lo tanto, un gran valor positivo corresponde a una fuerte excitación, mientras que un valor negativo pequeño corresponde a una débil inhibición.
- Funciones de transferencia. Antes de emplear la función de transferencia se debe, como lo indica el punto anterior, realizar la suma ponderada de las salidas de los nodos que alimentan a este, esto es:

$$\text{activación total} = \sum(w_{ij} x_j) - \theta_j$$

Donde θ_j es un término bias que se puede ver como la constante de una regresión lineal y puede o no incluirse en la ecuación anterior.

El resultado de la ecuación anterior sirve para calcular la salida del nodo y , la cual esta definida por:

$$y = f\left(\sum_{i=1}^n (w_{ij} x_i) + \theta_j\right)$$

Donde $f()$ puede ser cualquier función que se desee, como raíz cuadrada, log, e^x , etc. Pero las funciones mas empleadas son las mostradas en la siguiente figura.

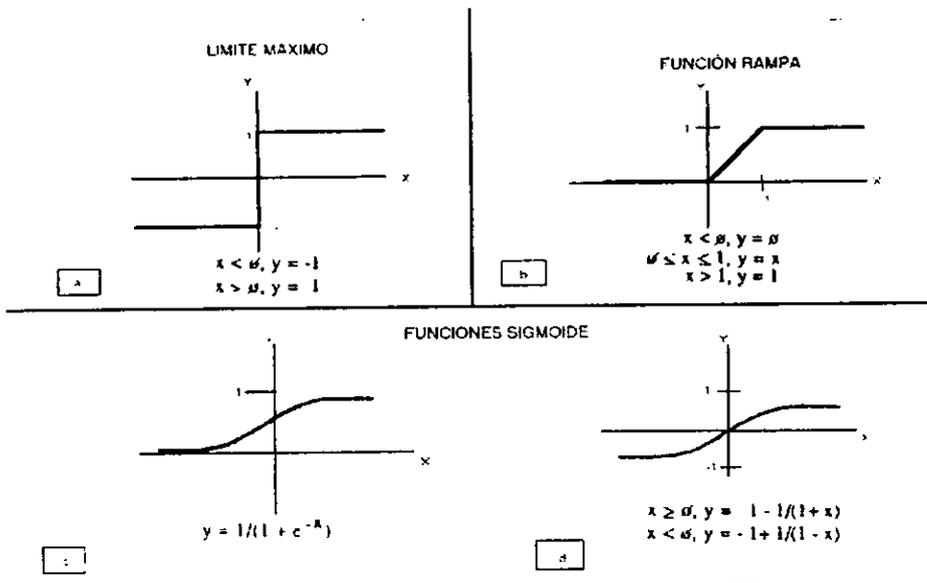


Figura 6 Funciones de transferencia utilizadas

Sin embargo la función sigmoide es la más empleada ya que se trata de una función continua y monotonica en la cual los efectos inhibitorios y excitatorios de los factores de peso son directos. Esto es, $w_{ij} < 0$ efecto inhibitorio, y $w_{ij} > 0$ efecto excitatorio.

$$f(x) = \frac{1}{(1 + e^{-x})}$$

2.4.3.-Topología.

A menudo se utilizan diferentes arquitecturas de topología de red con cientos ó miles de interconexiones y por lo tanto pesos (w)

Existen 3 opciones de conexión como lo muestra la Figura 7.

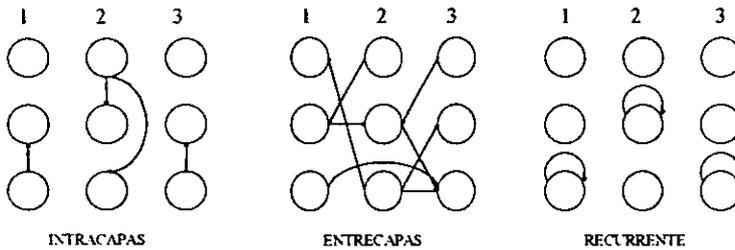


Figura 7.- Opciones de conexión de una red neuronal.

En las conexiones intracapa las salidas de un nodo alimentan a otros nodos en la misma capa. En las conexiones entrecapas las salidas de un nodo en una capa alimentan a otros nodos ubicados en una capa diferente, mientras que en las conexiones recurrentes la salida de un nodo alimenta a ese mismo nodo.

En el esquema de conexión entre capas se cuenta con dos opciones extra, que son:

- 1).-Conexiones de alimentación hacia atrás.
- 2).-Conexiones de alimentación hacia adelante.

Que se muestran en la siguiente figura.

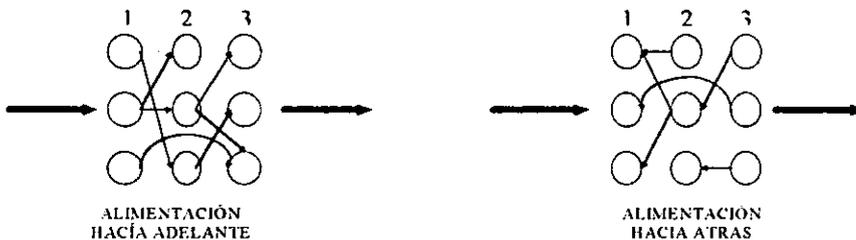


Figura 8.- Conexiones entre capas (opciones)

El tipo de problema que se trata de resolver determina cual topología se debe favorecer. Por ejemplo, si se desea desarrollar una red neuronal que se entrene a sí misma se debe usar un esquema de alimentación hacia atrás. En contraste en el modelado dinámico de reactores químicos en los que se trata de gráficar la respuesta del reactor basándose en una señal de entrada, se debe favorecer el esquema de alimentación hacia adelante.

La disponibilidad de la teoría matemática rigurosa para el entrenamiento de redes neuronales es limitada, y la mayoría de estas teorías están basadas en redes de alimentación hacia adelante ya que son las de mayor aplicación para la ciencia y la ingeniería, y las mas fáciles de implementar (ver apéndice A)

2.4.4.-Aprendizaje en las Redes Neuronales.

A diferencia de los sistemas expertos tradicionales, en donde el conocimiento se representa explícitamente en forma de reglas, las redes neuronales generan sus propias reglas durante la etapa de aprendizaje ó entrenamiento.

Se entiende por aprendizaje, a la adaptación de los parámetros de la red o pesos, de forma tal que el ajuste entre el vector de entrada y el de salida sea el optimo, esto es, que la correlación entre entradas y salidas tenga un porcentaje de error mínimo. Específicamente a este tipo de aprendizaje se le conoce como aprendizaje supervisado.

Pero existe otro tipo de aprendizaje llamado no-supervisado en el cual la red se organiza internamente, ya que tan solo se le presenta el vector de entradas y no existe una salida deseada si no una función de optimización, de manera tal que cada uno de los nodos responde de manera individual a los diferentes estímulos.

En general el aprendizaje se lleva a cabo con alguna variación de cualquiera de las siguientes técnicas:

Aprendizaje Hebbian.- En esta técnica, el peso de una conexión hacia la entrada de un nodo aumenta, tanto si el valor de la entrada es alto como si el valor de la salida es alto. En términos biológicos esto significa que una conexión entre dos nodos es reforzada cada vez que se lleva a cabo la sinapsis entre ellas.

Aprendizaje por regla delta.- Las variaciones de esta técnica se basan en la reducción del error entre la salida deseada y la salida generada por la red. Esto se realiza modificando los pesos de las conexiones.

Aprendizaje competitivo.- Los nodos compiten entre sí, y aquel que proporcione la respuesta más fuerte a una determinada entrada, se modifica a sí mismo para igualar lo más posible el valor de la entrada.

Hay dos pasos previos para poder resolver el problema del aprendizaje:

- 1) Se debe especificar la topología de la red, así como el conjunto de datos de entrada-salida.
- 2) Se debe especificar una regla de aprendizaje, que es el procedimiento mediante el cual se ajustarán los pesos de manera que el valor de salida generado se aproxime al valor de salida deseado.

Existen diferentes reglas de aprendizaje, entre las que se encuentran la memoria bidireccional asociativa, la regla de Hopfield, la regla de Grossberg, etc. (ver apéndice A). Sin embargo la técnica de propagación hacia atrás es la que se emplea con mayor frecuencia y la que se empleara en este trabajo.

2.4.5.- Propagación Hacia Atrás

En esencia la propagación hacia atrás es un método para calcular derivadas de forma exacta y eficiente en cualquier sistema compuesto de subsistemas elementales, representados por funciones diferenciables. Por lo que tiene muchas aplicaciones que no comprenden a las redes neuronales como tales, sin embargo es la herramienta más usada en este campo para llevar a cabo la tarea del aprendizaje o entrenamiento.

Antes de especificar la regla de aprendizaje, se debe definir exactamente en que forma el vector de salidas de la red depende de sus entradas y pesos. En las redes neuronales de alimentación hacia adelante la lógica empleada es la siguiente:

$$x_i = X_i \quad 1 \leq i \leq m \quad (1)$$

$$net_i = \sum_{j=1}^{i-1} w_{ij} x_j + \theta_j \quad m < i \leq N+n \quad (2)$$

$$x_j = s(net_j) \quad m < j \leq N+m \quad (3)$$

$$y_i = x_{i-N} \quad 1 \leq i \leq n \quad (4)$$

donde:

m = neuronas de entrada

N = neuronas escondidas

n = neuronas de salida

X_i = vector de entradas

y_i = vector de salidas

En este caso net_i representa el nivel total de voltaje que excita a la neurona, y x_i representa la intensidad de salida resultante en ocasiones también se le llama “nivel de activación de la neurona”.

θ_i se le conoce como valor bias o valor umbral, no es otra cosa que un peso constante W_a y puede considerarse como la constante de una regresión lineal. Sin embargo se obtiene el mismo resultado asumiendo que una de las entradas es siempre igual a uno. Cabe hacer notar que este valor es opcional.

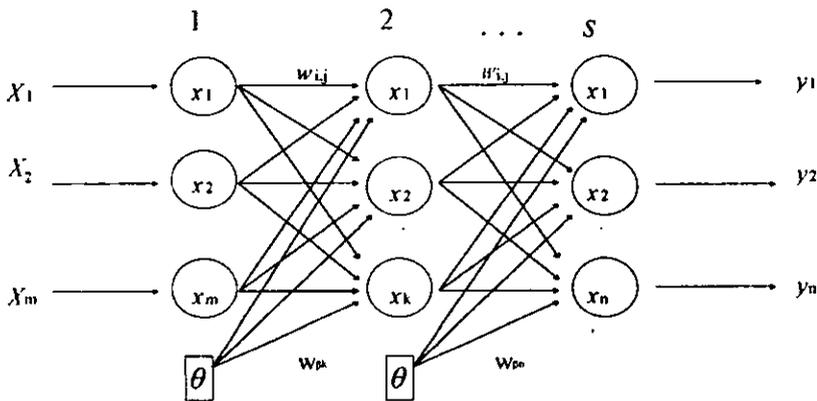


Figura 9.-Topología de red usada para la propagación hacia atrás

Como puede verse en la figura 9, las ecuaciones 1 a 4 definen la topología de la red, la cual es de alimentación hacia adelante con $S-1$ términos bias. Esto se logra limitando el número de conexiones entre neuronas, en general uno puede eliminar tantos o tan pocos pesos W_{ij} (igualándolos a cero) como se desee.

En el algoritmo de propagación hacia atrás, se modifican los pesos de forma tal que el error cuadrado sobre el conjunto de datos de entrenamiento, sea mínimo.

$$E = \sum_{t=1}^T E = \sum_{t=1}^T \sum_{i=1}^n \frac{1}{2} [y_i(t) - y(t)]^2 \quad (5)$$

Éste, es simplemente un caso especial del bien conocido método de mínimos cuadrados, bastante usado en estadística, econometría e ingeniería; lo que hace única a la propagación hacia atrás es la forma en que se minimiza esta expresión. El enfoque usado se ilustra en la Figura 10.

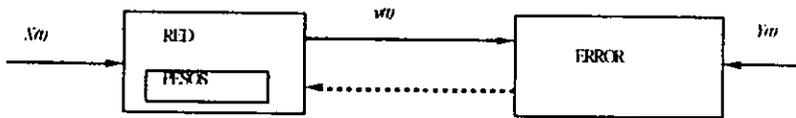


Figura 10.- Enfoque utilizado

Este algoritmo se inicia asignando valores aleatorios (usualmente en el rango de -0.1 a 0.1) a los pesos. Posteriormente se calculan las salidas $y(t)$ y los errores $E(t)$ con ese conjunto de pesos. Después se calculan las derivadas de E con respecto a todos los pesos; esto se indica en la Figura 10 mediante las líneas punteadas. Si al aumentar el valor de uno de los pesos, el error se incrementa, entonces ajustamos ese peso disminuyendo su valor. Mientras que si al aumentar su valor el error disminuye entonces se continúa aumentando.

Una vez ajustados todos los pesos, el procedimiento anterior se reinicia y se continúa haciéndolo hasta que el error disminuye

La singularidad de este método descansa en la forma usada para calcular las derivadas para todos los pesos en una sola iteración a través del sistema.

Muchos artículos dedicados a la propagación hacia atrás sugieren que solo se utiliza la regla de la cadena convencional para calcular las derivadas de E con respecto a todos los pesos, pero esto no es del todo cierto, ya que se calculan las derivadas ordenadas de una función objetivo, por lo que la regla de la cadena convencional se convierte en:

$$\frac{\partial^* \text{objetivo}}{\partial z_i} = \frac{\partial \text{objetivo}}{\partial z_i} + \sum_{j'} \frac{\partial^* \text{objetivo}}{\partial z_j} * \frac{\partial z_i}{\partial z_j} \quad (6)$$

Donde las derivadas con superíndices representan derivadas ordenadas, y las derivadas sin superíndices representan derivadas parciales ordinaria. Esta regla de la cadena solo es valida para sistemas ordenados donde los valores calculados. se puedan calcular uno a uno (si es necesario) en el orden $z_1, z_2, z_3, \dots, z_n, \text{objetivo}$. Las derivadas parciales simples representan el impacto directo de z_i en z_j a través del sistema de ecuaciones que determina z_j . La derivada ordenada representa el impacto total de z_j sobre *objetivo*, tomando en cuenta el efecto directo y el indirecto.

Se puede escribir la derivada ordenada del *objetivo* con respecto a z_j con $F_{-} z_j$, que puede ser descrito como "la alimentación hacia atrás de z_j ". En la propagación hacia atrás básica la variable *objetivo* de interés es el error E . Esto cambia la apariencia de la regla de la cadena (Ec. 6).

$$F_{-} z_i = \frac{\partial E}{\partial z_i} + \sum_{j'} F_{-} z_j * \frac{\partial z_j}{\partial z_i} \quad (7)$$

Para un conjunto de pesos W dado, es fácil usar las ecuaciones 1 a 6 para calcular $y(i)$ y $e(i)$ para cada patrón i . El truco esta en como calcular las derivadas.

Se usara el prefijo F_{-} para indicar la derivada ordenada de E con respecto a cualquier variable que éste precedida por este prefijo.

Por ejemplo:

$$F_{-y}(t) = \frac{\partial E}{\partial y_i(t)} = y_i(t) - y_i(t) \quad (8)$$

Que se obtiene simplemente de diferenciar la ecuación 5. Usando la regla de la cadena para derivadas ordenadas como lo expresa la ecuación 7.

$$F_{-x_i}(t) = F_{-y_i}(t) + \sum_{j=1}^{i-1} W_{ij} * F_{-net_j}(t) \quad (9)$$

$i = N-n, \dots, m-1$

$$F_{-net_i}(t) = S'(net_i) * f_{-x_i}(t) \quad (10)$$

$i = N-n, \dots, m-1$

$$F_{-W_{ij}} = \sum_j F_{-net_j}(t) * x_j(t) \quad (11)$$

Donde S' es la derivada de $S(Z)$ definida en la ecuación 3 y F_{y_k} se considera cero para $k \leq 0$. Nótese que la ecuación 10 requiere que nos movamos en dirección inversa a través de la red, para de esta forma, calcular las derivadas. Y es esta propagación inversa, lo que da a la propagación hacia atrás su nombre.

Un poco de álgebra a partir de la ecuación 3, nos muestra que :

$$S'(z) * (1-s(z)) \quad (12)$$

Finalmente para adaptar los pesos, el método usual es fijar

$$\text{Nuevo } W_{ij} = W_{ij} - \text{vel. de aprend.} * \delta * W_{ij} \quad (13)$$

Donde *vel. de aprend.* es una constante.

3.- DESCRIPCION DEL MODELADO UTILIZANDO REDES NEURONALES.

3.1.-MODELADO DEL PROCESO.

Para el cumplimiento de los objetivos de este trabajo se utilizará un sistema que pretende emular las condiciones que se tendrían en un reactor tubular (es decir el control de la temperatura a lo largo del mismo, que es una de las variables más importantes dentro de este sistema) el cual se analizará en régimen permanente y las entradas se modificarán de manera aleatoria, al mismo tiempo se registrarán todos los cambios que se realicen y los resultados obtenidos se utilizarán en el entrenamiento de la red.

Debido a que varios investigadores se han encargado de demostrar que el desempeño de las redes neuronales depende de la topología seleccionada y del entrenamiento dado [2][7][11][15][19], no nos abocaremos a tratar de comparar los sistemas de control tradicionales con los basados en redes neuronales. Y es por esta misma razón que no se llevara a cabo una evaluación numérica del modelo dinámico del sistema. Sin embargo con el fin de demostrar la complejidad de la simulación numérica del sistema, se desarrollara el modelo matemático del mismo.

Los datos adquiridos se procesarán, filtrarán para remover el ruido presente en los sistemas dinámicos para poder ser alimentados a la red, se entrenaran y validaran diversas topologías, para poder seleccionar una de ellas. El microcontrolador se programará con la red seleccionada para obtener así un desarrollo en línea del sistema y poder implementar las acciones de control.

3.2.-MODELADO Y CONTROL UTILIZANDO REDES NEURONALES.

Este tipo de modelado ha tenido un gran desarrollo dentro del campo de la ingeniería química, en aplicaciones como la detección de fallas, el procesamiento de señales, el modelado en sí de los procesos químicos y por supuesto el control. Las razones para el desarrollo de estas son las siguientes:

- Primero, los recientes avances en la tecnología computacional y el procesamiento en paralelo han hecho del uso de las redes neuronales artificiales mas económicamente posible que en el pasado.
- Segundo, debido a que las redes neuronales están compuestas de redes de funciones básicas no- lineales, tienen la habilidad de proporcionar buenos modelos de datos ejemplo y requieren de un mínimo o nulo conocimiento a-priori de la tarea que vayan a realizar.
- Tercero, las redes neuronales tienen el potencial de resolver ciertos tipos de problemas complejos que no tienen un resultado satisfactorio por los métodos tradicionales.

3.3.-METODOS DE CARACTERIZACIÓN.

Los modelos de los procesos pueden ser desarrollados a partir de principios fundamentales, tales como la ley de la conservación de la masa, energía y momentum, y otros principios de ingeniería química. Un modelo basado en principios fundamentales, es capaz de explicar el fundamento físico del problema y se le llama "modelo fenomenológico.

Este tipo de desarrollo da como resultado modelos no lineales demasiado complicados que requieren suposiciones que simplifiquen su solución. Sin embargo en muchos problemas industriales hay un conocimiento insuficiente del fenómeno físico del proceso, por lo que estos modelos son difíciles de obtener.

3.3.1.-Caracterización de Procesos con Redes Neuronales.

La caracterización de los modelos dinámicos de los procesos a partir de datos experimentales de entrada y salida usualmente emplean los siguientes pasos:

1. Diseño experimental
2. Adquisición de datos.
3. Procesamiento de datos.
4. Selección del modelo.
5. Estimación de los parámetros.
6. Validación del modelo.

Los últimos tres pasos son iterativos y el procedimiento de iteración permite obtener un modelo satisfactorio.

3.3.2.-Diseño Experimental.

El diseño experimental es una etapa muy importante, ya que en esta se determinan el tipo y tamaño de los cambios de entrada, la región de operación, el orden de cambio de las múltiples entradas y en general todas las características de las pruebas que se llevaran acabo.

Se debe tener cuidado para que la calidad del producto no se vea afectada porque estas pruebas se realizan en línea mientras opera la planta, así que se debe observar de cerca que tanto se puede permitir la variación de un dato de entrada. Y al mismo tiempo, los datos de entrada deben ser modificados por lo menos en cierto rango para que los datos enriquezcan la información dinámica. Debido a este conflicto de objetivos, el diseño experimental es una etapa crucial en la caracterización del proceso.

Si una salida del proceso se desvía de los límites aceptables, debe haber alternativas que permitan al operador hacer los cambios para compensar las entradas y que las salidas vuelvan a los límites aceptables. Pero el número excesivo de movimientos al tratar de regresar una variable a su límite puede dar como resultado correlaciones no deseadas. Por lo que los experimentos deben estar diseñados de tal forma que el conjunto de datos de entrenamiento incluya información de todas las regiones de operación.

3.3.3.-Adquisición de Datos.

Las plantas químicas se caracterizan generalmente por grandes constantes de tiempo y tiempos muertos, por lo que alcanzar el régimen permanente puede tomar varias horas. Es por esto que las pruebas en las plantas se realizan normalmente durante

varios días de manera continua. Las entradas se cambian de forma aleatoria de acuerdo a un calendario y todas las salidas se registran. Junto con la recolección de datos el proceso debe ser monitoreado para evitar fallas, tales como saturación de válvulas, falla de bombas, etc. Para así prevenir errores en los datos experimentales utilizados para caracterizar el proceso.

3.3.4.-Procesamiento de Datos.

Los datos obtenidos de las pruebas de planta no se pueden utilizar (tal cual se obtuvieron) en el estudio de caracterización, estos deben ser filtrados para remover el exceso de ruido, invariablemente presente en las aplicaciones de tiempo real. También deben eliminarse los datos causados por errores de medición, así como los bloques de datos donde se sabe que el proceso tuvo una falla. Todo esto con el fin de evitar que se corrompa el modelo.

3.3.5.-Selección del Modelo.

En los sistemas de control de datos muestreados, generalmente se representa un proceso multivariable de la siguiente manera:

$$y_k = f(y_{k-1}, y_{k-2}, y_{k-3}, \dots, y_{k-m}, x_{k-1}, x_{k-2}, x_{k-3}, \dots, x_{k-n}) \quad (15)$$

Donde y_k y x_k representan los vectores de entradas y salidas, el sufijo k se refiere al instante muestreado y f representa la relación funcional entre las entradas y las salidas. En los estudios clásicos de caracterización, se debe especificar la forma de la función que representa el comportamiento de las entradas y salidas y los parámetros de dicha función se deben determinar.

Usualmente se deben realizar suposiciones sobre el proceso tales como linealidad, régimen permanente, etc., y modelar el ruido por separado para representar la dinámica no modelada. Pero muchos de los procesos químicos industriales importantes son no lineales y a menudo es imposible especificar la relación funcional exacta entre las entradas y salidas.

Se ha encontrado que las redes neuronales son extremadamente funcionales en este contexto. No requieren que se especifique explícitamente la función. Solo se necesita especificar la topología o la estructura de la red. La especificación incluye el número de neuronas en la capa de entrada, la capa oculta y la capa de salida. El número de neuronas en las capas de entrada y salida se determinan generalmente por las entradas y salidas del proceso.

Los valores pasados de entradas y salidas se utilizan para formar el vector de entrada de la red neuronal. El número de valores anteriores de la entradas se pueden usar dependiendo de los tiempos muertos presentes en el sistema, mientras que el número de valores anteriores de las salidas depende del orden del proceso. El número de neuronas de las capas ocultas se especifican mediante el proceso de prueba y error. Si n_i , n_h y n_o son el número total de neuronas en cada capa, entonces el número de pesos, n_{wts} , en el modelo de la red esta dado por:

$$n_{wts} = (n_i + 1)n_h + (n_h + 1)n_o \quad (15)$$

3.3.6.-Estimación de los parámetros y validación del modelo.

Para el propósito del modelado, el conjunto de datos experimentales (preprocesados) de entrada-salida se divide en tres diferentes grupos; grupo de entrenamiento, grupo de validación cruzada y el grupo de prueba. Los datos en el grupo de entrenamiento

se alimentan a la red y los pesos se adaptan continuamente de forma tal que el error se minimice. Al final de cada iteración (donde una iteración se refiere a alimentar la red con todos los datos del grupo de entrenamiento). La red se utiliza para predecir las salidas del grupo de validación cruzada.

Cabe hacer notar que los pesos se cambian únicamente durante el entrenamiento y no durante la validación cruzada. Si la predicción del error en el grupo de validación cruzada es más grande que la tolerancia especificada, la red es nuevamente alimentada con los datos de entrenamiento para otra iteración.

Este proceso de entrenamiento y validación es continuo hasta que el error es menor o igual a la tolerancia especificada, se alcanza el número máximo de iteraciones, o el error del grupo de validación cruzada alcanza un mínimo con respecto al número de iteraciones, lo que ocurra primero. Los pesos obtenidos al final de este proceso caracterizan el modelo de redes neuronales del proceso multivariable.

Para validar el modelo obtenido e incrementar el grado de confianza en la habilidad de generalización, se prueba contra el tercer grupo de datos experimentales; el grupo de prueba. Si las predicciones correspondientes a este grupo de datos no son satisfactorias, entonces se debe modificar la estructura del modelo, ya sea cambiando el número de neuronas en la capa oculta o cambiando el número de valores anteriores en las entradas y/o salidas. Este proceso de selección de modelos, entrenamiento y validación es iterativo hasta que se obtiene un modelo satisfactorio.

4.-DESARROLLO EXPERIMENTAL

4.1.-CARACTERISTICAS DEL MODELO

Se ideó un sistema que mostrara una dinámica difícil de controlar, pero que al mismo tiempo fuera fácil de construir, barato y que de alguna manera representara alguno de los principales equipos de proceso dentro de la industria química. Por lo que después de mucho pensarlo se tomó la decisión de construir un sistema que en cierta forma emulase el comportamiento de un reactor tubular, y se hace énfasis en la palabra emular, debido a que en este sistema no se lleva a cabo ningún tipo de reacción química, sin embargo mantiene las principales características de este tipo de equipos como son los perfiles de temperatura y las características físicas del equipo.

Dicho sistema se esquematiza en la figura 11 y se encuentra constituido por:

- 1 PC 486 a 100mhz, 8 Mb en RAM, 1G HD (solo para las etapas de adquisición de datos y entrenamiento).
- 1 Microcontrolador "Tiny Giant" de Z-World Engineering. con procesador Z180, reloj a 9.216 Mhz, 512 Kb RAM, puertos seriales, EEPROM, batería de litio, SRAM, EPROM, reloj de tiempo y hora, detector de fallas en la corriente de alimentación, con una tarjeta de programación SB-PG de la misma compañía.
- 3 Sensores de temperatura General Instruments LM35DZ con un rango de temperatura de -55 a 150 °C.
- 1 Un metro de tubo de PVC de 3".
- 1 Un ventilador de 3" Panaflo FBH-08A12M.
- 1 Resistencias de calentamiento.
- 1 Interface RS-232.

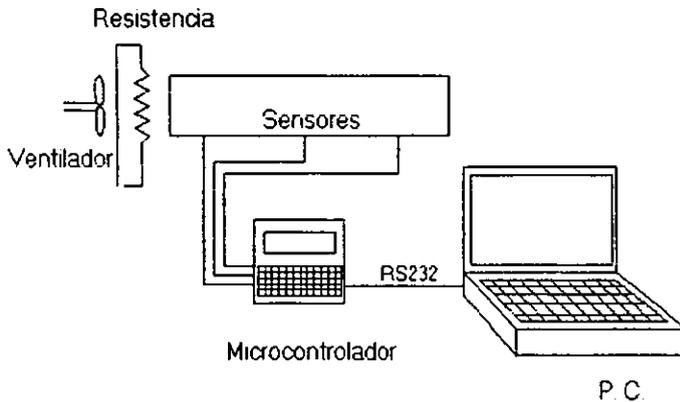


Figura 11.-Esquema del sistema experimental empleado

El objetivo de este sistema es demostrar que es posible controlar la temperatura dentro del tubo utilizando un paradigma de redes neuronales y más aun demostrar que es posible mantener la temperatura de los 3 sensores en una misma temperatura, cosa que es imposible utilizando estrategias de control tradicionales. Ya que para poder emplearlas, la correspondencia entre las variables manipulables y las variables controlables debe ser uno a uno, o de lo contrario (como en nuestro caso, ver Figura 12) se debe aplicar alguna de las dos soluciones existentes (Marlin, 1995) las cuales consisten en:

- a) Hacer una selección de la señal que se manda al microcontrolador procedente de los sensores.
- b) Mandar cada señal a un controlador diferente y posteriormente seleccionar entre las respuestas de cada controlador cual será empleada.

Sin embargo este enfoque aplica cuando:

1. Hay una variable manipulable y varias variables controlables potenciales.
2. Hay una relación causal entre la variable manipulable y cada variable controlable.
3. Hay un único punto de operación posible que satisface todos los objetivos de control en el régimen permanente.

Pero en nuestro caso estas soluciones no son apropiadas, ya que si bien se cumplen las dos primeras condiciones, no es así con la tercera y más importante, como es posible apreciar en la Figura 13 (perfil de temperatura).

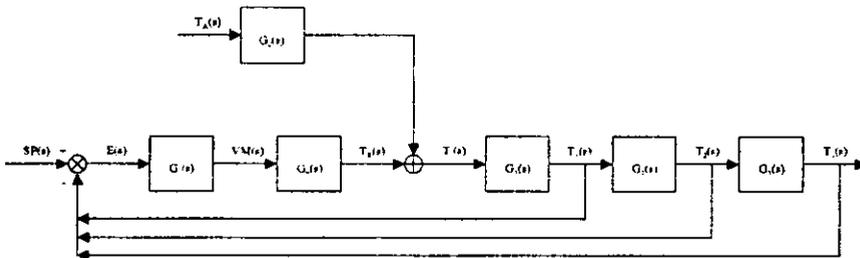


Figura 12.- Diagrama de bloques del sistema empleado

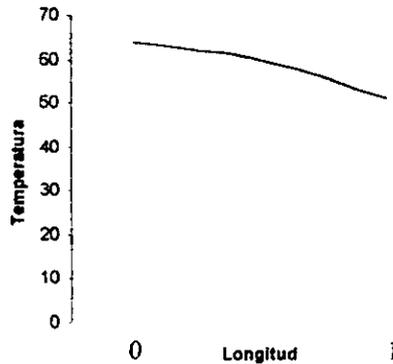


Figura 13.-Perfil de temperaturas del sistema a Régimen Permanente

En otras palabras, si se empleara alguna de las técnicas anteriores, se controlaría la temperatura en un sensor específico, no la temperatura a lo largo del tubo.

Es por esto y con el fin de cumplir con el objetivo que se decidió evaluar dos enfoques diferentes, el primero consiste en tomar un promedio de las temperaturas registradas por los sensores y mandar este promedio al controlador y el segundo consiste en entrenar a la red utilizando el registro de los tres sensores.

4.2.-CARACTERISTICAS DEL SOFTWARE.

Si bien existe un gran número de programas comerciales enfocados a la resolución de redes neuronales, también es cierto que ninguno de estos sirve a nuestros propósitos, debido a que son programas muy grandes (en extensión) y diseñados para sistemas operativos específicos. Es por esta razón, que se desarrolló el software que nos permitiera cumplir con los objetivos planteados y cuyas características son las siguientes:

1. Utiliza una topología de red del tipo feedforward en estratos o capas (slabs), cada una de las cuales contiene un número de neuronas definidas por el usuario.
2. Emplea como regla de aprendizaje una variación del paradigma de propagación hacia atrás, el cual modifica el coeficiente de aprendizaje dependiendo de la diferencia entre el error calculado y el error estimado, que se alimenta en la siguiente iteración con la finalidad de acelerar la convergencia de la red.
3. Utiliza un término "bias" por capa (exceptuando la de salida).
4. Es compacto (pocas líneas de programación)

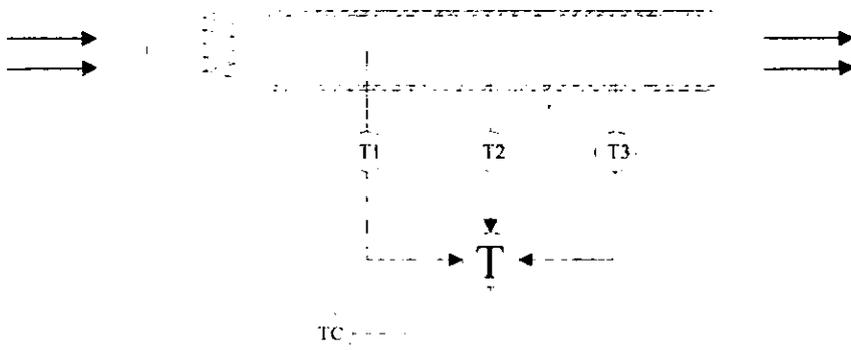
4.3.-CARACTERISTICAS DEL SISTEMA DE ADQUISICION DE DATOS

Como se menciona en el capítulo 2, el sistema de adquisición de datos es importante dentro de la generación del conjunto de datos para el entrenamiento y validación de la red. Por lo que se deben considerar las siguientes recomendaciones para hacerlo lo más eficiente posible.

1. Elegir los sensores de acuerdo a su resolución, ya que esta es la especificación más importante al diseñar el sistema de adquisición de datos.
2. Elegir una velocidad de muestreo apropiada, de acuerdo a la velocidad de respuesta del sistema.
3. Tratar de evitar la interferencia en el cableado, haciendo que este no sea muy largo.

4. Poner atención en la instalación del cableado, especialmente al hacer las conexiones a tierra.
5. Aislar las señales para proteger la P.C.
6. Calibrar el sistema antes de ponerlo en funcionamiento y verificar la calibración durante el servicio de manera regular.
7. Utilizar el software apropiado para el sistema y el controlador.
8. Utilizar memoria de acceso directo para mejorar el funcionamiento del sistema.

4.4.-MODELADO DINAMICO DEL SISTEMA



El balance de masa sobre este elemento diferencial de volumen nos da como resultado un flujo constante de aire, si consideramos despreciable la acumulación de masa, y podemos hacer esto sin mayores problemas, ya que nuestro principal objetivo es modelar los efectos de transferencia de calor. También podemos despreciar los efectos de transferencia de calor a lo largo del tubo en la dirección del

flujo. Bajo estas restricciones, el balance de energía del aire en el elemento diferencial de volumen esta dado por:

$$\rho C_v \frac{dT}{dt} = \frac{4}{\pi D_i^2 L} FC_p (T_0 - T) - \frac{4h}{D_i} (T - T_w) \quad (16)$$

Donde:

T temperatura del aire dentro del tubo

T_w temperatura de la pared del tubo

F flujo de aire

D_i diámetro interior del tubo

h , coeficiente de transferencia de calor al interior del tubo

ρ densidad molar del fluido (se supone constante)

C_v capacidad calorífica molar a volumen constante (se supone constante)

C_p capacidad calorífica molar a presión constante (se supone constante)

ΔZ longitud del elemento diferencial de volumen

La ecuación anterior representa el balance de energía por unidad de volumen en cualquier punto del tubo en cualquier instante de tiempo. Ya que es una sola ecuación con dos variables T y T_w , necesitamos otra ecuación. Esta nueva ecuación se obtiene del balance de energía en la pared del tubo. Suponiendo despreciable la conducción de calor a lo largo del tubo, tenemos:

$$\rho_T C_{PT} \frac{dT_w}{dt} = \frac{4h_i D_i}{(D_e^2 - D_i^2)} (T - T_w) - \frac{4h_a D_e}{(D_e^2 - D_i^2)} (T_w - T_a) \quad (17)$$

Donde:

ρ_T densidad del tubo (se supone constante)

C_T capacidad calorífica del tubo (se supone constante)

D_i diámetro interior del tubo

D_e diámetro exterior del tubo

h_i coeficiente de transferencia de calor al interior del tubo

h_a coeficiente de transferencia de calor al exterior del tubo

T_a temperatura ambiente (se supone constante)

Para finalizar, la ecuación para el elemento de calentamiento es la siguiente:

$$T_0 = T + \frac{W}{m_A C_{PA}} \quad (18)$$

Donde:

T_0 Temperatura del aire caliente

m_A masa de aire

C_{PA} capacidad calorífica del aire

De las ecuaciones anteriores, se ve claramente que a régimen permanente el sistema esta definido por:

$$0 = FC_p(T_{0s} - T_s) - h\pi D_1 L(T_s - T_{\infty s}) \quad (19)$$

$$0 = h\pi D_1 L(T_s - T_{\infty s}) - h_s \pi D_2 L(T_{\infty s} - T_{1s}) \quad (20)$$

Donde el subíndice "s" nos indica el valor de la variable a régimen permanente.

Condiciones iniciales:

$$T(0) = 0, \quad T_s(0) = 0$$

Sustituyendo la ecuación 18 en 16:

$$\rho C_V \frac{dT}{dt} = \frac{4}{\pi D_1^2 L} FC_p \left[\left(T_s + \frac{IV}{m_A C_{PA}} \right) - T \right] - \frac{4h_s}{D_1} (T - T_{\infty s}) \quad (21)$$

En términos de variables de desviación:

$$T' = T - T_s$$

$$T'_0 = T_0 - T_{0s}$$

$$T'_w = T_w - T_{ws}$$

$$T'_{i1} = T_{i1} - T_{is}$$

$$T' = T - T_s$$

Las ecuaciones 17 y 21 se convierten en:

$$\tau_1 \frac{dT'}{dt} = [(T'_{i1} + K_2 T') - T'] - K_1 (T' - T'_w) \quad (22)$$

$$\tau_2 \frac{dT'_w}{dt} = (T' - T'_w) - K_3 (T'_w - T'_{i1}) \quad (23)$$

Donde:

$$\tau_1 = \frac{\rho C_p \pi D_i^2 L}{4FC_p}$$

$$\tau_2 = \frac{(D_o^2 - D_i^2) \rho C_{pf}}{4h_i D_i}$$

$$K_1 = \frac{h_i \pi D_i L}{FC_p}$$

$$K_3 = \frac{h_o D_o}{h_i D_i}$$

$$K_2 = \frac{J}{m_i C_{pi}}$$

Si aplicamos transformadas de Laplace a las ecuaciones 22 y 23 y sustituimos las condiciones iniciales, obtenemos:

$$(\tau_1 s + 1 + K_1)T(s) = T_d(s) + K_2 V(s) + K_1 T_w(s) \quad (24)$$

$$(\tau_2 s + 1 + K_3)T_w(s) = T(s) + K_3 T_d(s) \quad (25)$$

Eliminando $T_w(s)$ del conjunto de ecuaciones algebraicas simultaneas:

$$[(\tau_2 s + 1 + K_3)(\tau_1 s + 1 + K_1) - K_1]V(s) = (\tau_2 s + 1 + K_3)T_d(s) + [(\tau_2 s + 1 + K_3) - K_1 K_3]T_d(s) \quad (26)$$

Se definen las funciones de transferencia del sistema como:

$$G_1 = \frac{T(s)}{V(s)} = \frac{(\tau_2 s + 1 + K_3)}{(\tau_2 s + 1 + K_3)(\tau_1 s + 1 + K_1) - K_1} \quad (27)$$

$$G_2 = \frac{T(s)}{T_d(s)} = \frac{(\tau_2 s + 1 + K_3) - K_1 K_3}{(\tau_2 s + 1 + K_3)(\tau_1 s + 1 + K_1) - K_1} \quad (28)$$

Por lo tanto, el sistema se encuentra representado por la siguiente ecuación:

$$T(s) = G_1 V(s) + G_2 T_d(s) \quad (29)$$

4.5.-METODOLOGIA

4.5.1.-Adquisición de Datos

Para poder generar un conjunto de datos y utilizarlo en el entrenamiento se dispone de tres sensores de temperatura a lo largo del tubo, con los cuales se miden las variaciones de la temperatura para las diferentes condiciones en las que se trabaja, ya que durante el proceso de entrenamiento se varían las características del sistema, de forma tal que se obtengan datos de todas las regiones de trabajo posibles.

Primero se registra el comportamiento del sistema sin ningún tipo de control hasta que se alcanza el régimen permanente, esto para poder determinar la velocidad de muestreo y obtener el perfil de temperatura.

Posteriormente se procede a trabajar con el sistema a ciclo abierto (open-loop) variando en diversas ocasiones el set-point, para de esta forma enriquecer el conjunto de datos de entrenamiento.

4.5.2.-Procesamiento de Datos.

A los datos así obtenidos se procede a filtrarlos, esto es a remover aquellos datos que son evidentemente dispersos con respecto a la tendencia de los demás, que como se explico anteriormente pueden ser causados por errores de medición, interferencias en la señal de adquisición, etc.

Se crean tres conjuntos de datos a partir del conjunto inicial, un conjunto de datos de entrenamiento, un conjunto de datos de validación cruzada y un conjunto de datos de prueba.

4.5.3.-Entrenamiento y validación del modelo.

Se elige la topología de red que se empleara, y utilizando los conjuntos de datos generados en la etapa anterior se entrena a la red alimentando los datos haciendo que los pesos se adapten de tal forma que el error global se minimice. posteriormente se alimenta a la red el conjunto de datos de validación cruzada, y al final de este proceso se obtiene nuevamente el error global, el cual es comparado con una tolerancia preestablecida. Si el error es mayor que la tolerancia se reentrena a la red hasta que se alcance un rango en el cual el error global sea menor o igual a la tolerancia. se alcance el máximo de iteraciones permitidas o el error del grupo de validación sea mínimo con respecto al numero de iteraciones.

Para entender mejor esto, el proceso se ilustra en la figura 14.

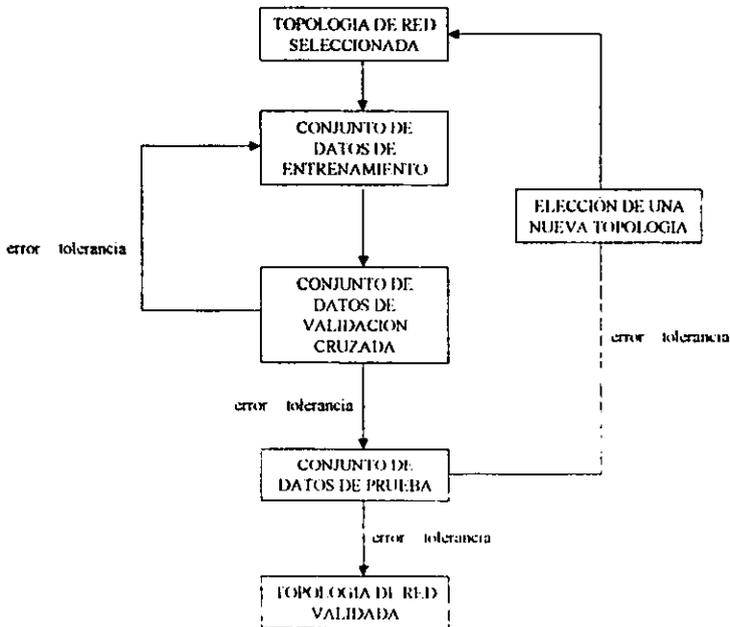


Figura 14.- Procedimiento empleado para entrenar y validar la red

4.5.4.-Elección del modelo de red neuronal.

La elección del modelo que mejor se adapte a las condiciones de trabajo, no es otra cosa que la simple selección del modelo que presente el error global más pequeño.

5.- RESULTADOS

A continuación se presentan los resultados obtenidos durante la etapa de adquisición de datos para formar el conjunto de datos de entrenamiento, prueba y validación de las diferentes topologías de redes neuronales que se probaron.

Gráfica G1

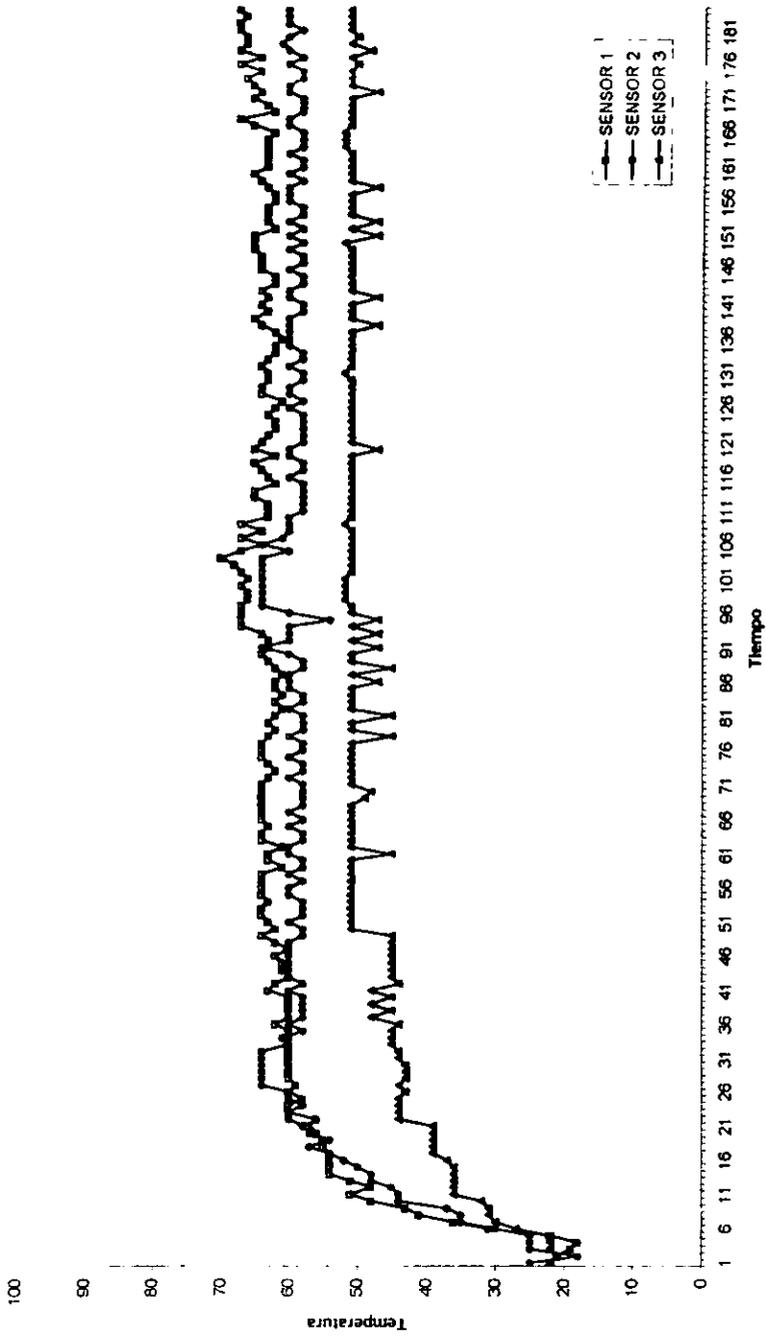
La gráfica que a continuación se presenta muestra el comportamiento del sistema, el cual se utilizó sin control alguno para así conocer el perfil de temperatura del mismo. Como se puede observar el sistema tiene un comportamiento creciente hasta alcanzar el régimen permanente.

Así mismo se puede observar que en dicha gráfica existen variaciones en la temperatura aun cuando ya se encuentra en régimen permanente. A estas variaciones se les conoce como ruido, y se encuentra presente en todos los sistemas dinámicos, por lo que se considera normal este comportamiento. Este ruido puede ser causado por interferencias en la señal de adquisición de datos o por variaciones en la temperatura ambiente, ya que cabe recordar que el sistema no se encuentra térmicamente aislado.

Este conjunto de datos se utilizó para definir la velocidad de muestreo y obtener el perfil de temperatura (figura 13) a lo largo del tubo.

Una vez que se obtuvo la información anterior se procedió a generar el conjunto de datos para el entrenamiento de la red neuronal.

Comportamiento del sistema a regimen permanente



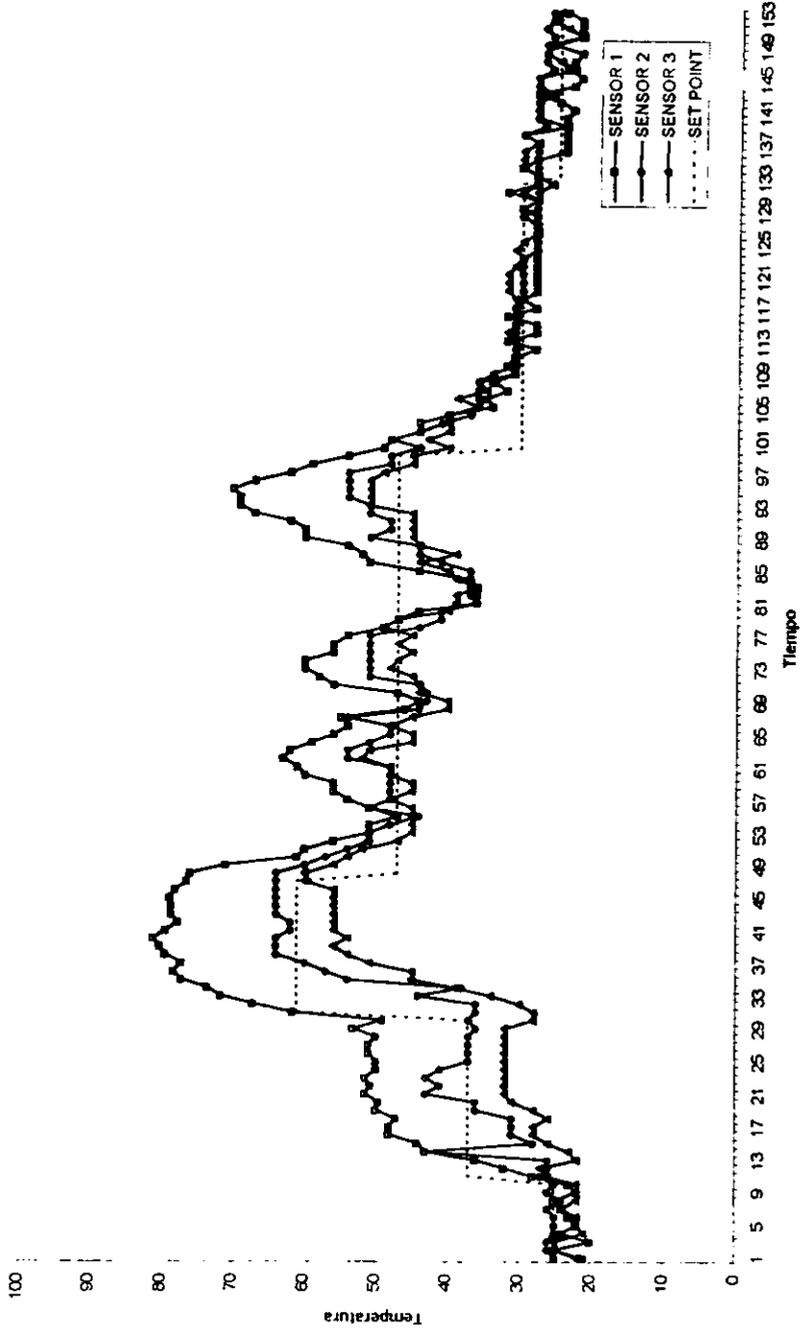
Gráfica G2

La gráfica muestra la respuesta del sistema, tomando en cuenta las siguientes características:

1. Variable manipulable: elemento de calentamiento.
2. Variables controlables: temperatura registrada por los sensores 1, 2 y 3.
3. Sistema a ciclo abierto (open-loop) con control tipo ON-OFF.
4. Variaciones de set-point con el fin de enriquecer los datos del conjunto de entrenamiento.

Se intentó que después de variar el set-point las temperaturas tendieran rápidamente a normalizarse y a ajustarse a la variación.

Respuesta del sistema (Control Manual)

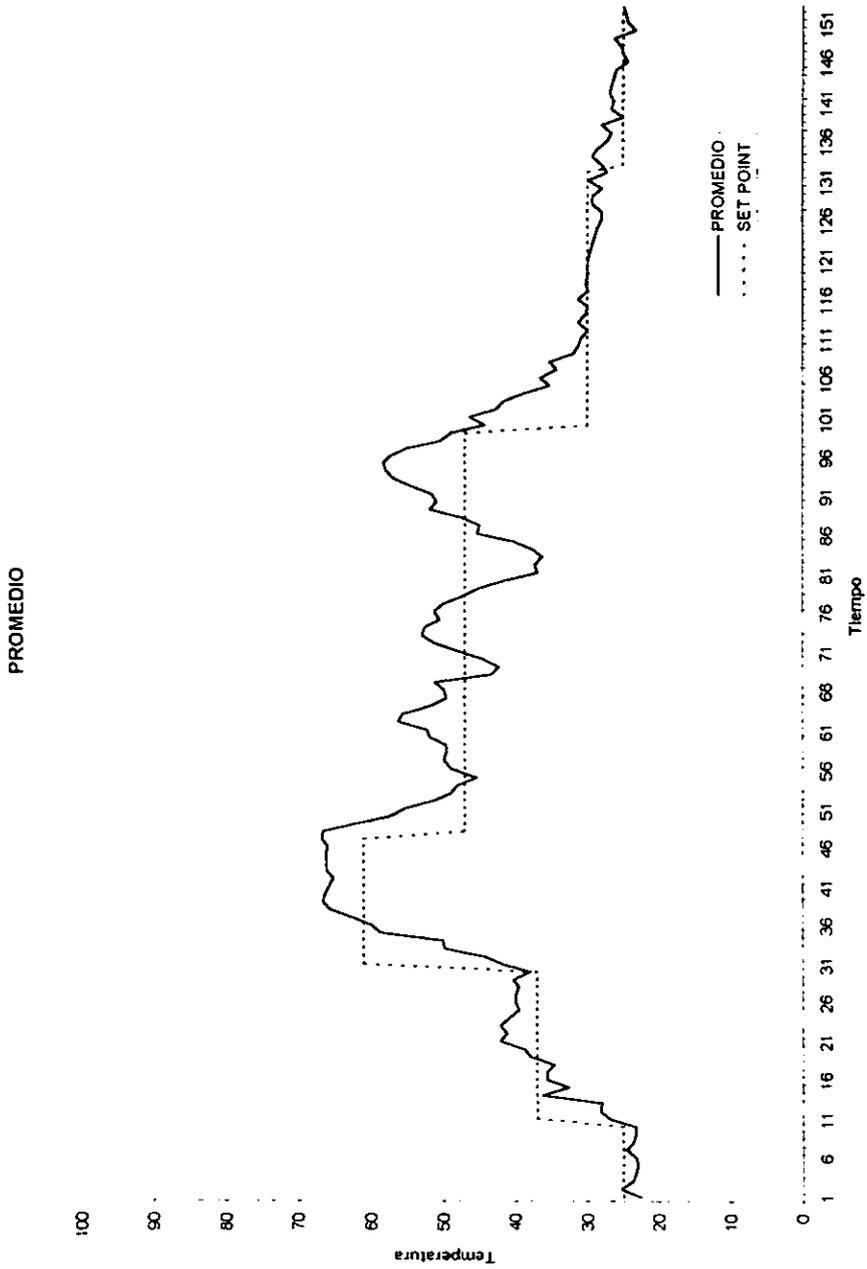


Gráfica G3

En esta gráfica se encuentra representado el valor promedio de las temperaturas 1, 2 y 3 obtenidas anteriormente. Estos datos sirvieron como conjunto de entrenamiento para las topologías de red de dos entradas y una salida. Dichas entradas son, el promedio de temperaturas del sistema y el set-point.

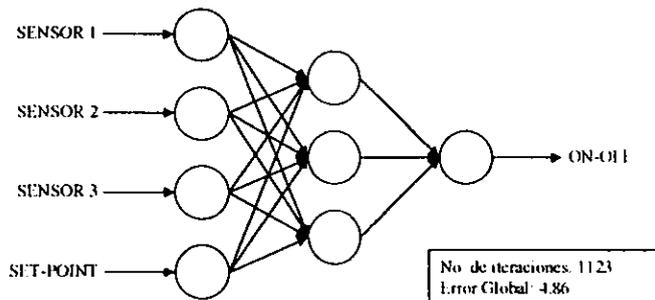
En esta sección se presentan las gráficas de las respuestas generadas por las diferentes topologías de red una vez entrenadas y validadas. Solo se muestran los resultados finales ya que son estos los de verdadero interés para el desarrollo de esta investigación.

Para emplear al máximo las características de reconocimiento de patrones de las redes neuronales se entrenaron 3 redes utilizando los datos generados por los tres sensores del sistema (Gráfica G2).

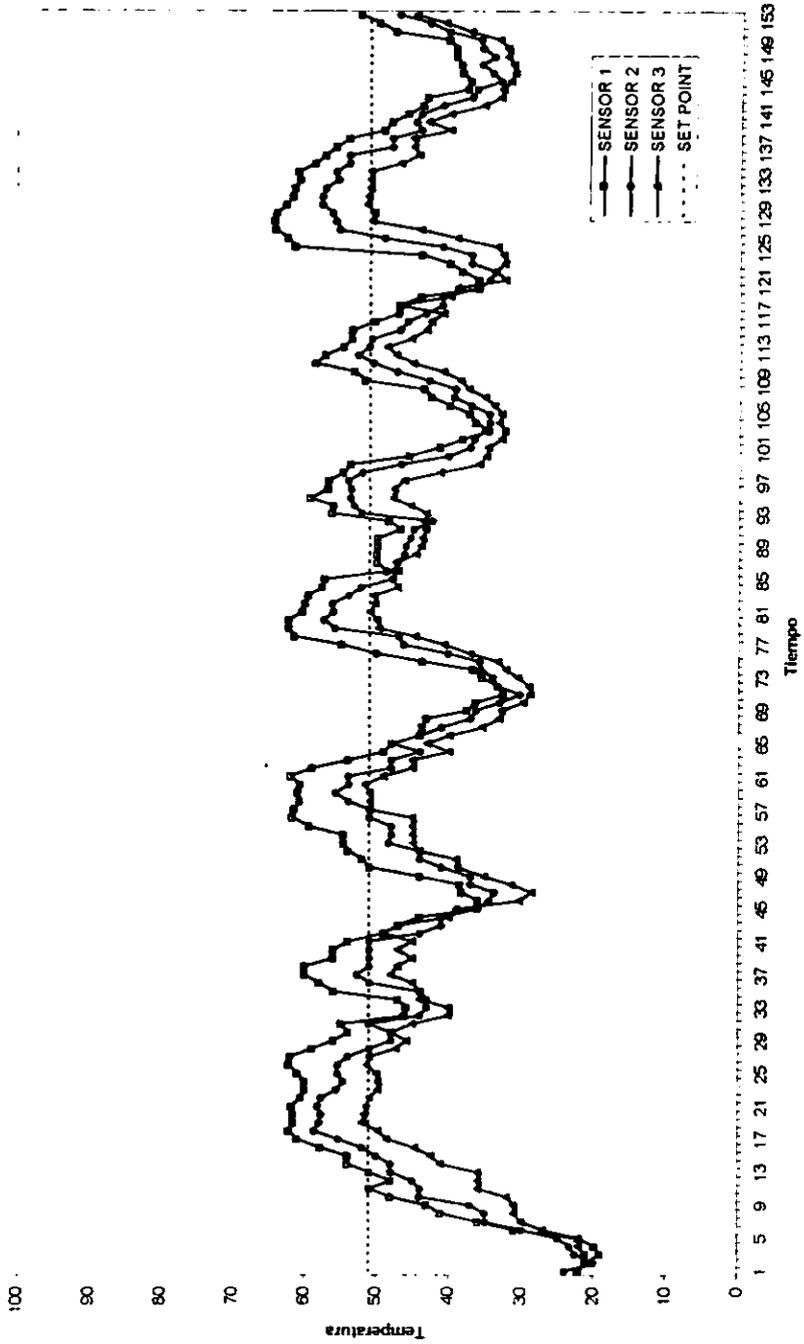


Gráfica G4

Esta gráfica muestra el comportamiento del sistema controlado utilizando la topología de red $4 \times 3 \times 1$, es decir 4 neuronas en la capa de entrada que son las temperaturas adquiridas por los sensores y el set-point, 3 neuronas en la capa oculta y una neurona en la capa de salida.



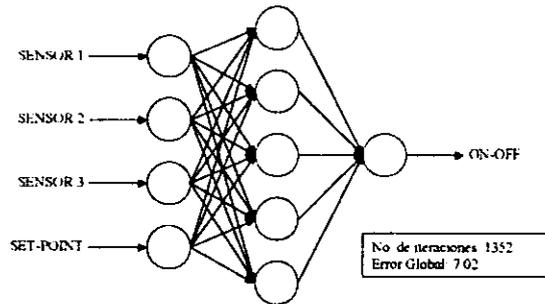
Respuesta del sistema Red 4X3X1



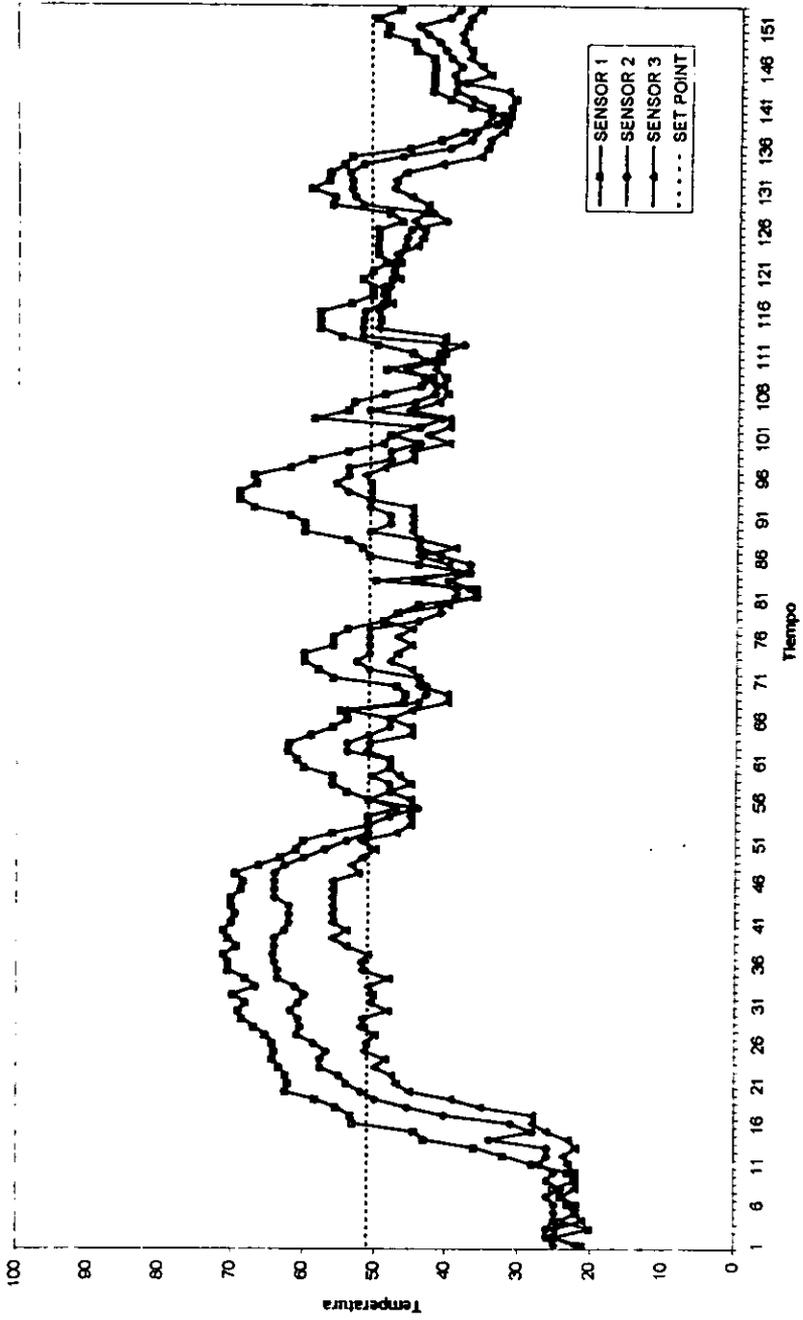
Gráfica G5

Esta gráfica representa la respuesta del sistema, el cual utilizó la topología de red $4 \times 5 \times 1$, que como se puede observar se aumentan dos neuronas en la capa oculta y se mantiene el set-point a la misma temperatura.

Como es posible observar, las variaciones de las temperaturas con respecto al set-point son menores que en la gráfica anterior.

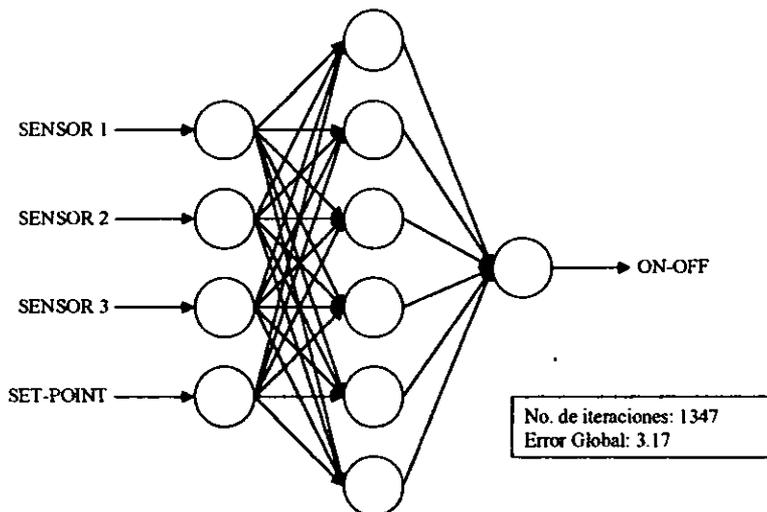


Respuesta del sistema Red 4X5X1

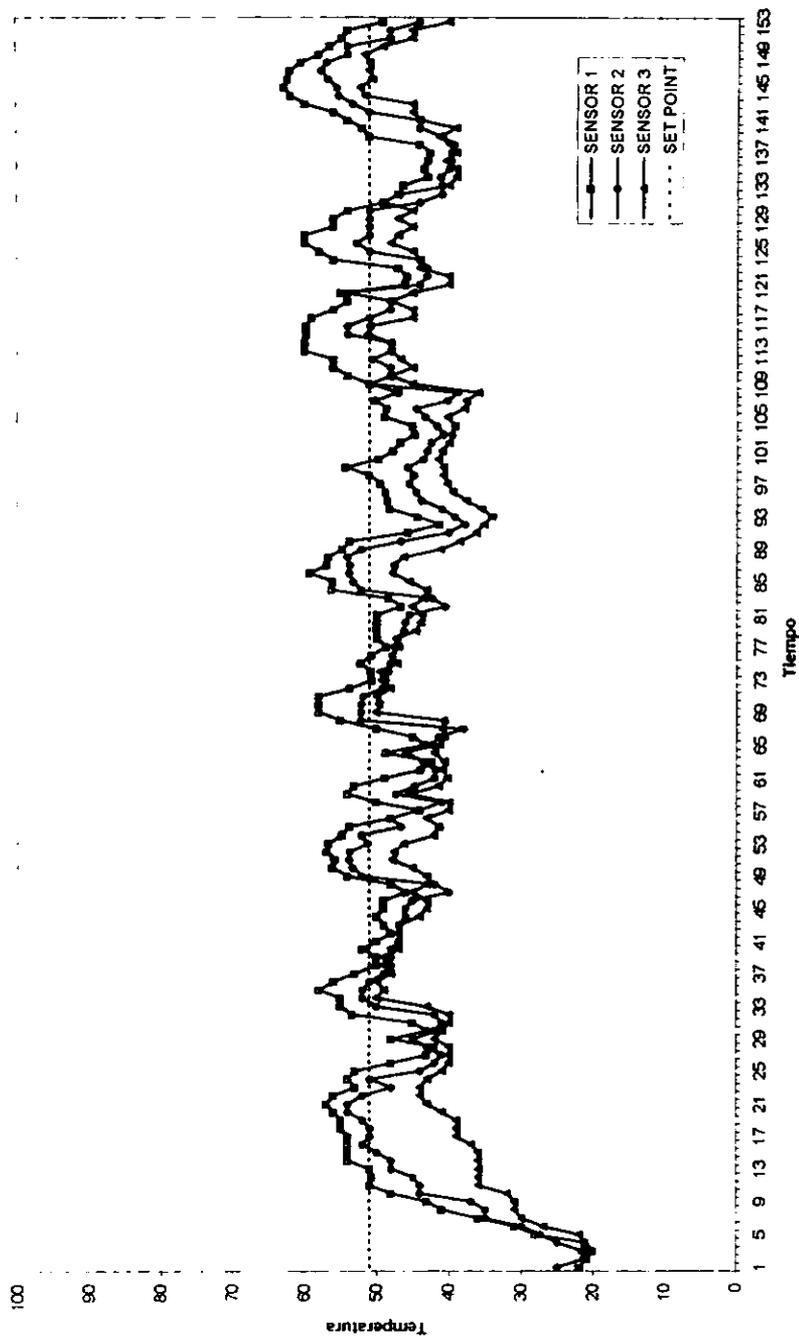


Gráfica G6

Esta gráfica representa la respuesta obtenida del sistema que emplea la topología de red $4 \times 6 \times 1$, se aumenta una neurona en la capa oculta con respecto al sistema anterior con lo cual se logra aumentar la exactitud del control. Cabe mencionar que el análisis se hará posteriormente.

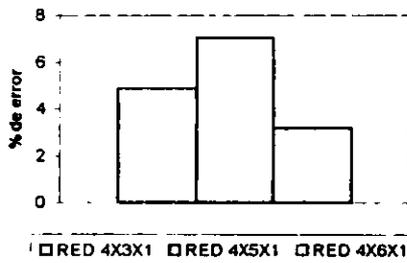


Respuesta del sistema Red 4X6X1

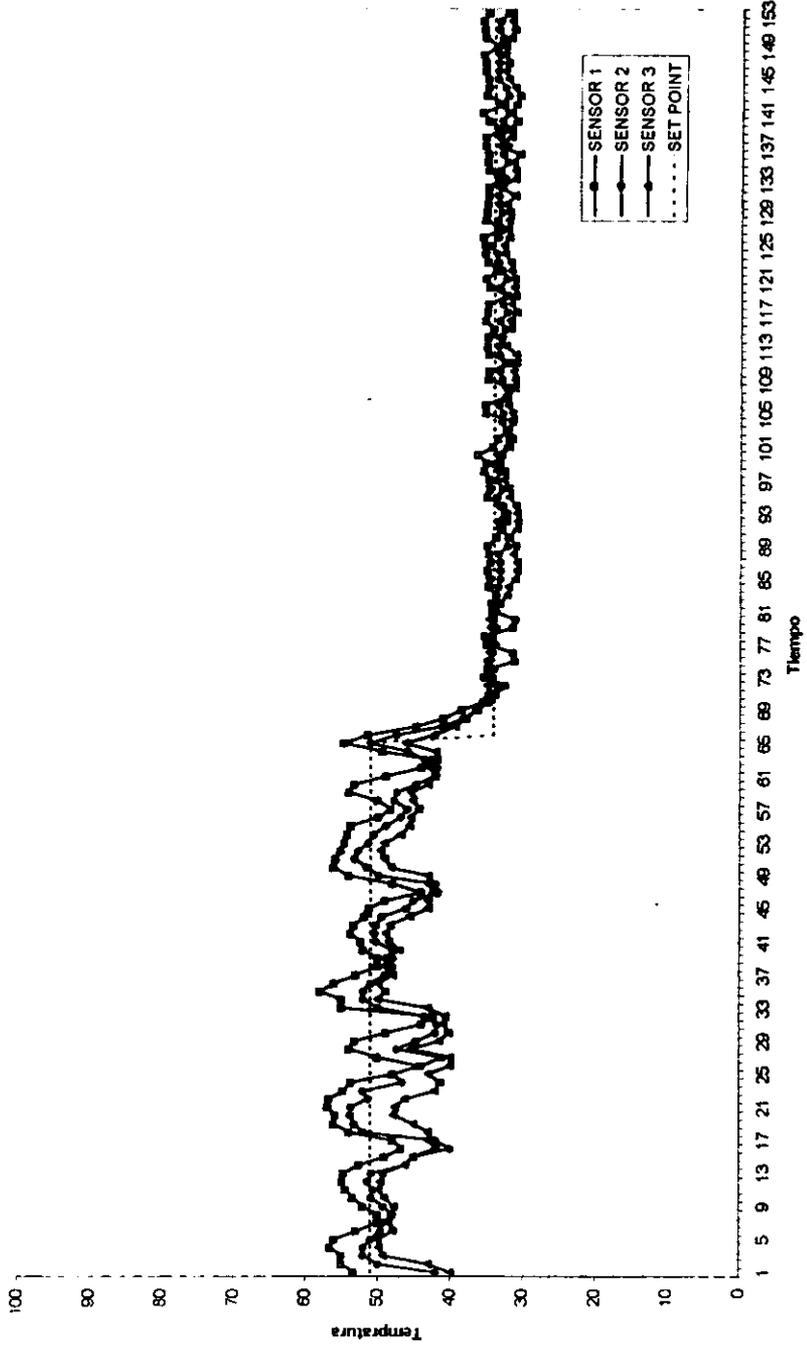


Gráfica G7

Una vez que se obtuvieron las respuestas utilizando tres topologías de red diferentes con el mismo set-point, se eligió la que presentara menores variaciones (en este caso la de topología 4×6×1, como puede verse en la gráfica de barras) y se realizó una prueba variando el set-point para observar el comportamiento y adaptación del sistema a dicha variación.

**Figura 15**

Respuesta del sistema Red 4X6X1 Cambio de Set-Point

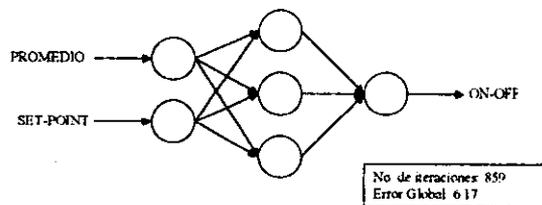


Como se menciona anteriormente, sé penso en dos enfoques diferentes para solucionar el problema de manejar tres variables controlables y solo una variable manipulable, uno de estos fue el manejar un valor promedio de las variables controlables.

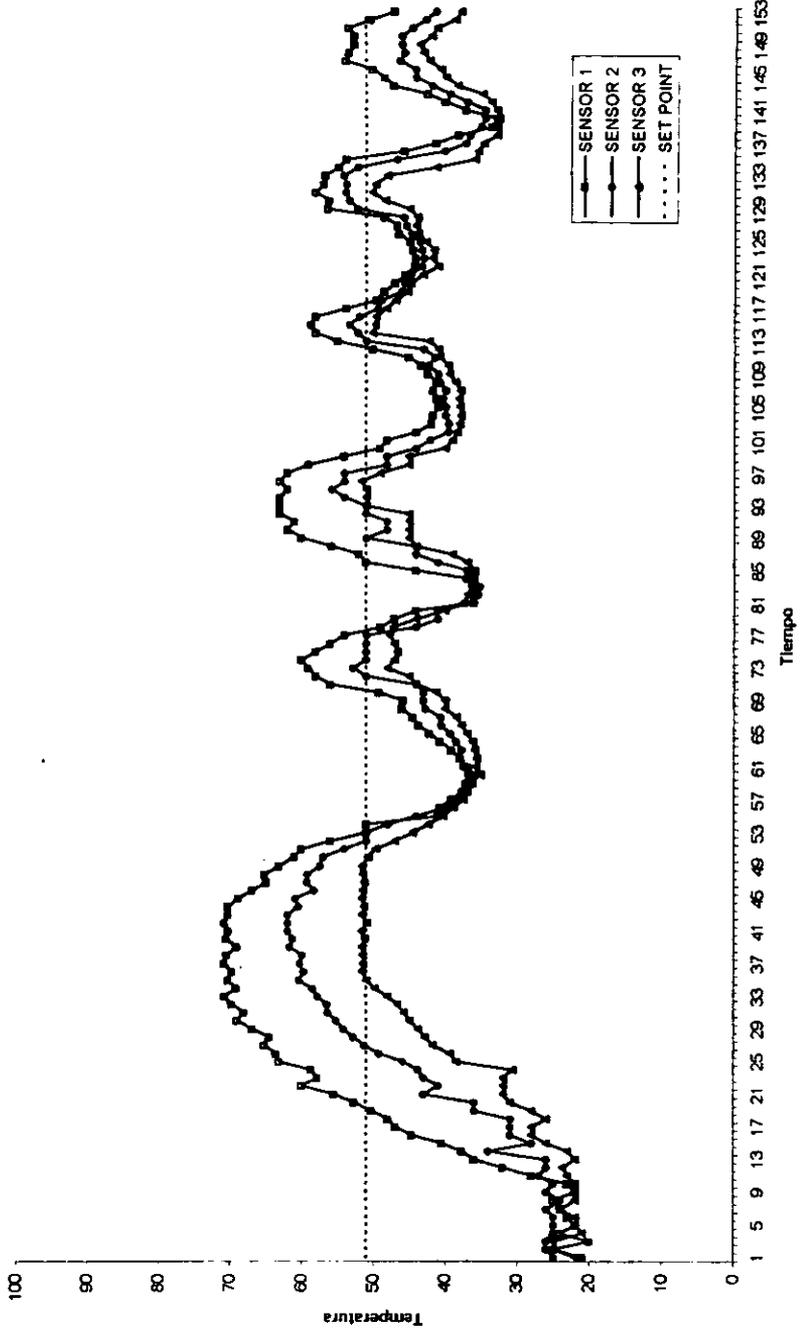
Las gráficas presentadas en esta sección son el resultado del empleo del conjunto de datos promedio obtenidos durante la etapa de adquisición (Gráfica G3), utilizados para el entrenamiento.

Gráfica G8.

En la gráfica se muestra la respuesta obtenida del sistema que emplea la topología de red $2 \times 3 \times 1$, es decir 2 neuronas en la capa de entrada, 3 neuronas en la capa oculta y una neurona en la capa de salida. Además se mantiene constante el set-point.

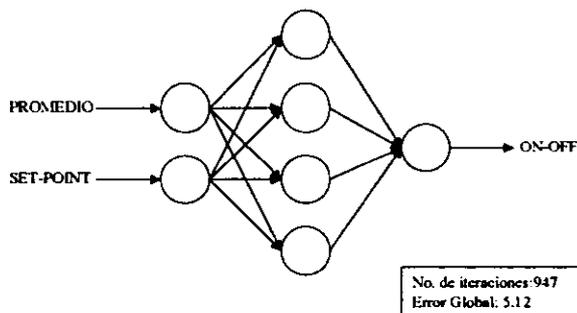


Respuesta del sistema Red 2X3X1

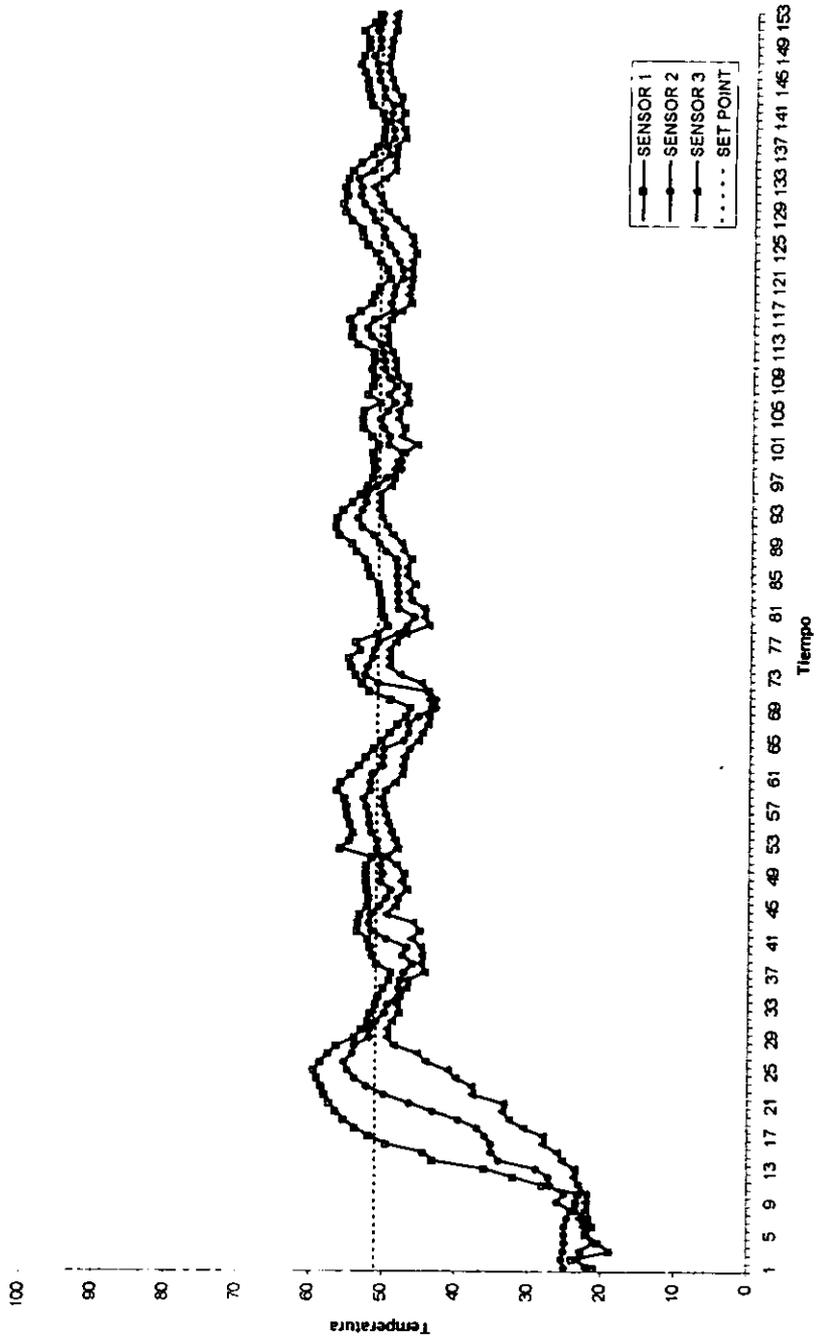


Gráfica G9.

En esta gráfica se muestra la respuesta obtenida del sistema con una topología de red $2 \times 4 \times 1$ que como se puede observar se aumento una neurona en la capa oculta y las variaciones de temperatura con respecto al set-point son menores con respecto al anterior.

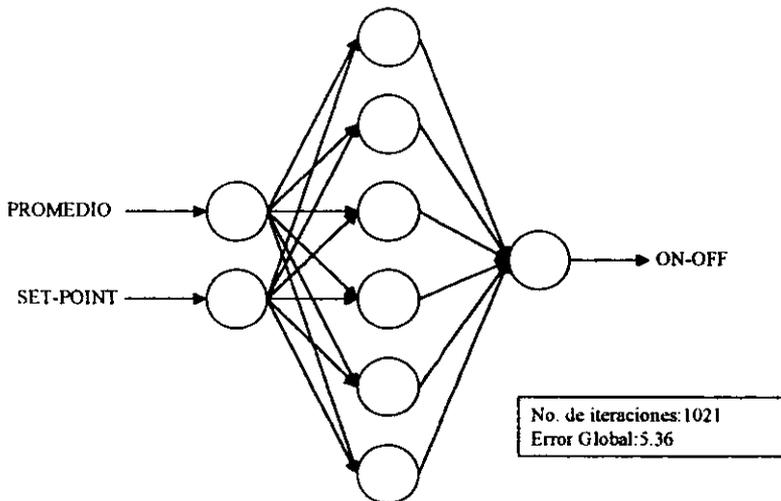


Respuesta del sistema Red 2X4X1

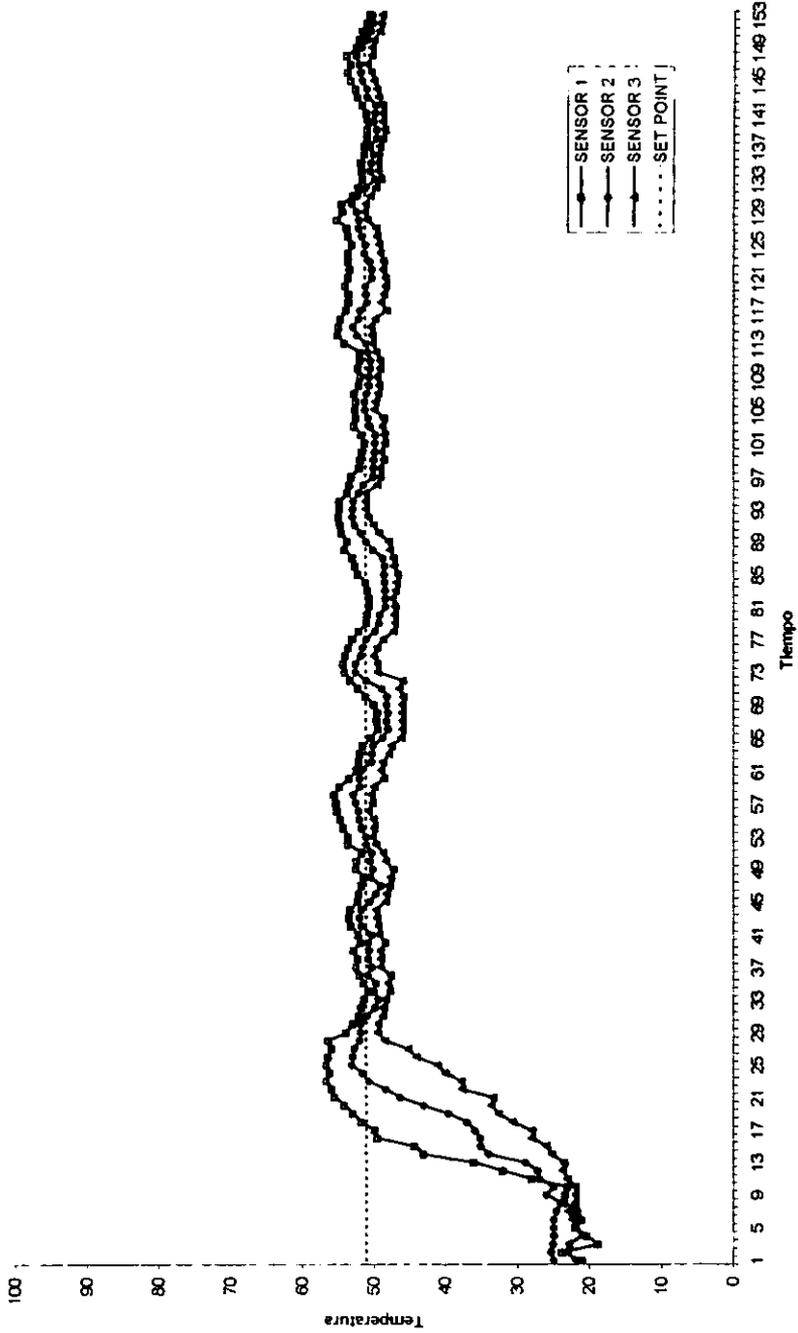


Gráfica G10.

La gráfica muestra la respuesta obtenida del sistema que utiliza una topología de red $2 \times 6 \times 1$, con una variación de 2 neuronas en la capa oculta, es decir 2 mas que la anterior y como se observa en dicha gráfica las variaciones disminuyen conforme se aumentan las neuronas en la capa oculta, lo que ayuda al control ya que lo hace mas fino.

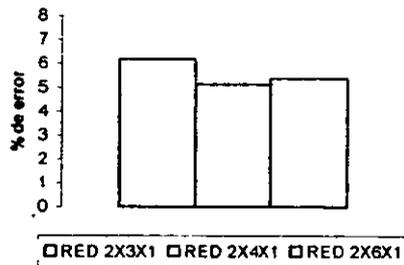


respuesta del sistema Red 2X6X1

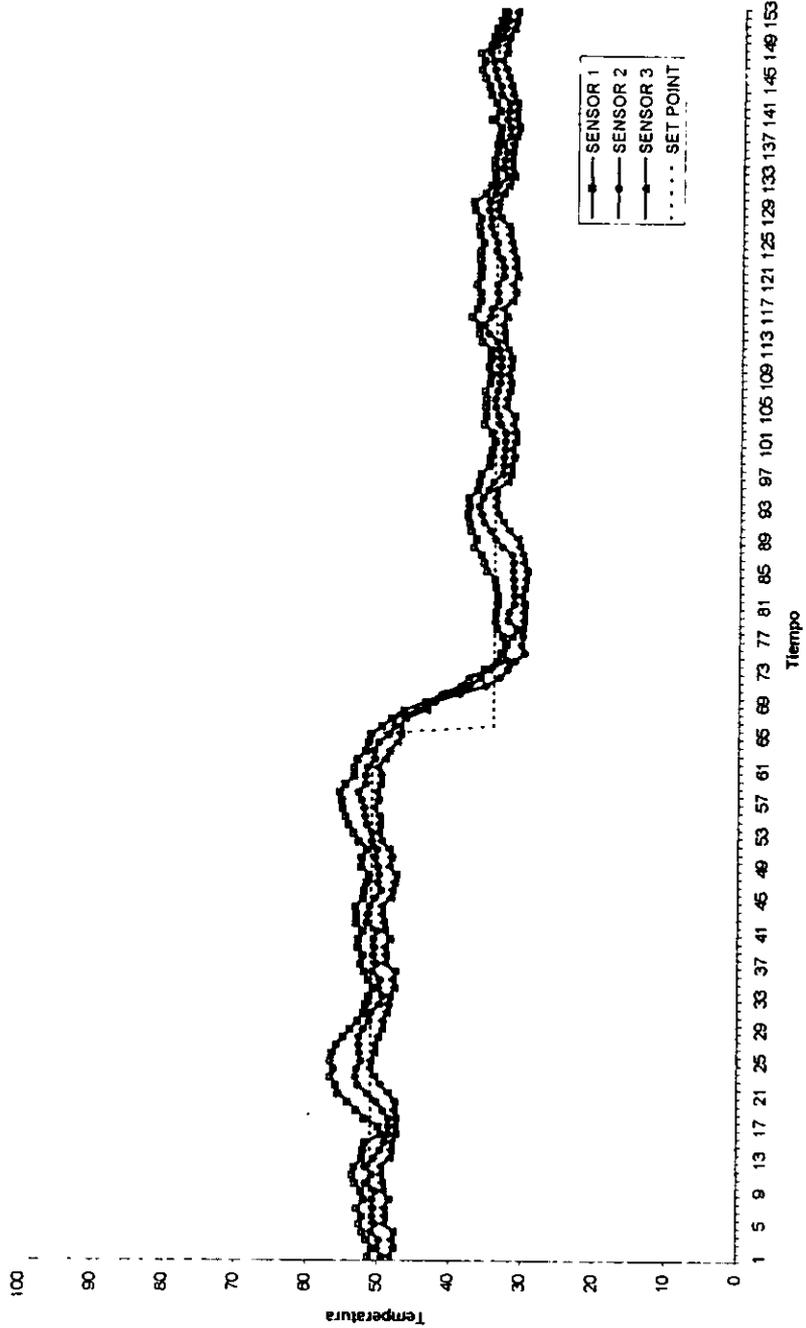


Gráfica G11.

Una vez que se realizaron las pruebas anteriores manteniendo el set-point constante, se realizó una prueba utilizando la topología de red $2 \times 4 \times 1$ (que como puede verse en la gráfica de barras es la que presenta un menor porcentaje de error), y modificando el set-point para observar el comportamiento de la red y la adaptación a los cambios en el sistema y como se puede observar disminuyeron las variaciones en la temperatura y la adaptación al cambio es rápida.

**Figura 16**

Respuesta del sistema Red 2X4X1 Cambio de Set-Point



ANALISIS DE RESULTADOS

Adquisición de datos:

En este respecto no se tuvo ningún problema, ya que se siguieron al pie de la letra las recomendaciones dadas en el capítulo 4.

1. Se eligieron los sensores de acuerdo a su resolución (-55 a 150°C con $\pm 0.1^\circ\text{C}$ de error), ya que esta es la especificación más importante al diseñar el sistema de adquisición de datos.
2. Se eligió una velocidad de muestreo de 10 segundos (solo para la adquisición del conjunto de datos de entrenamiento), la que se consideró apropiada de acuerdo a la velocidad de respuesta del sistema.
3. Se trató de evitar la interferencia en el cableado, haciendo que este no fuese muy largo (1.5 m).
4. Se puso atención en la instalación del cableado, especialmente al hacer las conexiones a tierra.
5. Se aislaron las señales para proteger la P.C. (utilizando el microcontrolador y la tarjeta de programación).
6. Se calibró el sistema antes de ponerlo en funcionamiento y se checo la calibración durante el servicio de manera regular.
7. Se utilizó el software apropiado para el sistema y el controlador. (Desarrollado específicamente para este proyecto utilizando lenguaje de programación Dynamic C).
8. Se utilizó memoria de acceso directo para mejorar el funcionamiento del sistema. Una vez que se eligió la red adecuada para controlar el sistema, se programó en memoria EPROM.

Gracias a esto fue posible obtener el conjunto de datos de entrenamiento (Gráfica 2) del que se pueden distinguir las siguientes características: las variaciones del set-point cubren todas las regiones de operación del sistema, y el control es poco preciso debido a que el sistema se operó manualmente, lo que también tuvo como consecuencia que se obtuviera una gran cantidad de ruido en los datos. Sin embargo este ruido fue filtrado de forma tal que el rango de valores se mantuviese entre 0 y 1, aumentando así la robustez del sistema.

Entrenamiento:

En un principio se pretendía llevar a cabo el proceso de adquisición de datos y aprendizaje de forma completamente automática y en línea (siguiendo el procedimiento mostrado en la Figura 15).

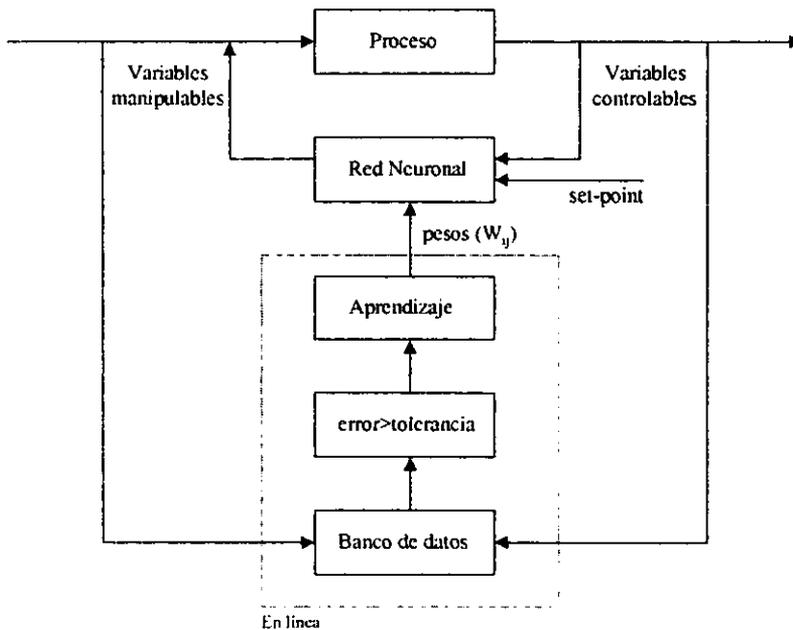


Figura 17.- Procedimiento que se pretendía implementar

Pero debido a las siguientes deficiencias: baja velocidad de procesamiento (9.216 Mhz) en el microcontrolador, falta de sistema operativo y memoria ROM insuficiente (512 Kb), esto no fue posible por lo que el procedimiento se modifico, quedando de la siguiente forma (Figura 16):

1. Se propuso una topología de red, y el entrenamiento fuera de línea. En este punto cabe hacer notar que el conjunto de datos de entrenamiento y validación cruzada se fueron enriqueciendo (después de cada 50 iteraciones) con datos seleccionados de la respuesta con el conjunto de prueba. Si bien esto hizo que el proceso se realizara mas lentamente, también permitió que se obtuvieran mejores resultados, ya que se fue eliminando el ruido de este conjunto.
2. Se programó el microcontrolador con una estructura de red idéntica a la usada en el entrenamiento y se opero en línea, realizando el proceso de adquisición de datos en tiempo real.

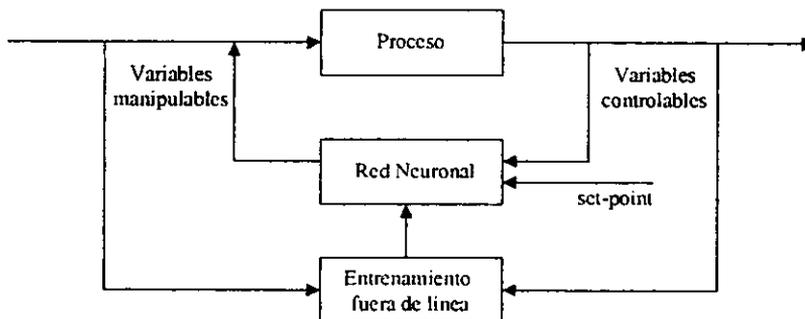


Figura 18.- Procedimiento empleado en el entrenamiento de las redes.

Como se puede observar en la gráfica G1, el comportamiento del sistema presenta un aumento gradual de las temperaturas a lo largo del tubo hasta alcanzar una

temperatura máxima, la que varía para cada uno de los tres sensores, siendo para el primero de hasta 71 °C, la del segundo de hasta 57 °C y del tercero de 53 °C.

Por esta razón, para las pruebas en operación se fijó un set-point de 51°C. Ya que se consideró a esta región de operación como una de las más difíciles de controlar debido a que se encuentra cercana al limite.

Elección del modelo:

Como ya se había explicado anteriormente, se propusieron dos soluciones al problema de control, una empleando la respuesta de los tres sensores y el set-point, y la otra usando un promedio de las temperaturas registradas por los sensores y el set-point.

Por obvias razones ambas soluciones requieren de topologías de red diferentes, así como de conjuntos de datos, ya que estos están definidos por las entradas y salidas del sistema.

En este caso se emplearon las siguientes topologías para resolver el problema de control:

| | |
|-------------------|--------------------|
| 4X3X1 (Gráfica 4) | 2X3X1 (Gráfica 8) |
| 4X5X1 (Gráfica 5) | 2X4X1 (Gráfica 9) |
| 4X6X1 (Gráfica 6) | 2X6X1 (Gráfica 10) |

Al analizar todas estas gráficas podemos darnos cuenta de que todas las respuestas son bajo amortiguadas y que al aumentar las neuronas en la capa oculta no necesariamente aumenta la calidad del control (como puede verse en el gráfico de barras, figura 16).

ESTA TESIS NO DEBE
SALIR DE LA BIBLIOTECA

Se procedió a elegir la topología adecuada para nuestro sistema, y ya que con ambos procedimientos se obtuvieron buenos resultados, se decidió hacer una última prueba.

En este punto cabe reiterar el hecho de que al aumentar el número de neuronas en la capa escondida, no necesariamente también se aumenta la exactitud del modelo. Como puede verse al comparar los porcentajes de error de las topologías 2x4x1 y 2x6x1.

Se tomaron las dos topologías con menor error global (una para cada tipo de procedimiento) y se probaron en línea, variando el set-point hasta 35°C (Gráficas 7 y 11). Como puede verse ambas pruebas resultaron exitosas, ya que la respuesta a la variación del set-point, fue rápida y el ajuste de las temperaturas fue incluso mejor.

Sin embargo había que elegir una de estas dos topologías, por lo que tomando el criterio del error global se eligió la red con 4 neuronas en la capa de entrada, 6 neuronas en la capa escondida y 1 en la capa de salida, como la que mejor controla el sistema.

6.- CONCLUSIONES

1. Se requiere poco o nulo conocimiento del sistema (ya que no es necesario determinar ninguna de las ganancias del proceso, el controlador, el elemento final de control, etc.).
2. Se requiere una gran cantidad de datos y de tiempo (si se quiere un buen modelo del proceso) para poder entrenar la topología de red seleccionada.
3. El proceso de selección de la red óptima se realiza mediante prueba y error, ya que no se puede saber a priori (antes del entrenamiento) como se comportará la red.
4. El algoritmo de control basado en redes neuronales es simple, fácil de programar y provee de un buen control para casi cualquier tipo de proceso. Esta flexibilidad es debida a la gran cantidad de parámetros ajustables con que cuenta (y que pueden ser aumentados o disminuidos a voluntad) cuyos valores son modificados mediante las rutinas de entrenamiento de la red.
5. El control es robusto (Insensitivo a cambios en las condiciones del proceso o a errores en su modelado)
6. Debido a sus características modulares, es perfectamente compatible con las técnicas de control moderno, como el control cascada, feedforward, inferencial, predictivo, etc. Por lo que es posible mejorar el algoritmo básico sin descartarlo.

7. La puesta a punto (tuning) del controlador se realiza con datos reales del proceso y no se requiere de técnicas especiales, ya que esto no es mas que una extensión de la etapa de entrenamiento.
8. El sistema es flexible debido a las características propias del microcontrolador y de las redes neuronales.
9. Sencillez de programación en comparación con los sistemas tradicionales de inteligencia artificial.
10. Provee de un buen control a bajo precio.

7.- BIBLIOGRAFIA

- 1) Baratti. R. Vacca, G. Servida, A.: "Neural Network Modeling of the Distillation Columns". Hyd. Procc. 1995.
- 2) Bhat N. and T.J. McAvoy. "Use of Neural Nets for Dynamic Modeling and Control of Chemical Process Systems". Computers Chem. Engng. 14. (1990).
- 3) Carullo A. et al. "Ultrasonic Distance Sensor Improvement Using a Two-Level Neural Network". Instrumentation and Measurement 1996.
- 4) Dirion J. L., Cabassud M. "Development of Adaptive Neural Networks for Flexible Control of Batch Process". Chem Eng. 1996.
- 5) Holland. Ch D. "Unsteady State Process with Applications". Prentice Hall. Englewood.Cliffs 1966.
- 6) Hoskins J. C. and D. M. Himmelblau. "Artificial Neural Network Models of Knowledge Representation in Chemical Engineering". Computers Chem. Engn. 13. (1993).
- 7) Jagannathan S., Lewis F. L. "Discrete-Time Neural Net Controller for Class of Nonlinear Dynamical Systems". Automatic Control 1996.
- 8) Jean Phillippe D. Davor A. P. "Dynamic Recurrent Neural Networks". Systems, man and Cybernetics. 1996.
- 9) Kajarla T. W., D. M. Himmelblau and R. Miikkulainen. "Data Rectification Using Recurrent Neural Networks". In Proc. Int. Joint Conf. On Neural Networks. (1992).
- 10) Kramer M. A. and J. A. Leonard. "Diagnosis Using Backpropagation Neural Networks- Analysis and Criticism." Computers Chem. Engng. 14 (1990).
- 11) Lee M. and S. Park "A New Control Scheme Combining Neural Networks Based Feedforward Control With Model Predictive Control". Presented at AIChE Annual Meeting Chicago (1990)

- 12) MacMurray, J. Himmelblau, D. "Modelling and Control of a Packaged Distillation Column Using Artificial Neural Networks". Computer Chem. Engng. 1995.
- 13) Marios M. P. "Stable Adaptive Neural Control Scheme for Nonlinear System". Automatic Control 1996.
- 14) McAvoy, T. J., Dong, D. "Nonlinear Principal Component Analysis Based on Principal Curves and Neural Networks" Computer Chem. Engng. 1996.
- 15) Megan, L., Cooper D. J. "A Neural Network Strategy for Disturbance Pattern Classification and Adaptive Multivariable Control". Computer Chem. Engng. 1995.
- 16) Montague G. A., M. T. Tham, M. J. Willis and A. J. Morris. "Predictive Control of Distillation Columns Using Dynamical Neural Networks". 3rd IFAC Symposium on Dynamics and Control of Chemical Reactors, Distillation Columns and Batch Process. (1992).
- 17) Nagy I. "Introduction to Chemical Process Instrumentation". Elsevier Science Publishing 1992.
- 18) Ramasamy S., Deshpande P. B. "Consider Neural Networks for Process Identification". Hyd. Procc. 1995
- 19) Saint_Donat J., N. Bhat and T. J. McAvoy. "Neural Net Based Model Predictive Control". Int J. Contr. 54 (1991).
- 20) Tsai C., Chang C. T. "Dynamic Process Diagnosis Via Integrated Neural Networks". Computers Chem. Engng. 1995
- 21) Ungar H. Lyle. "Process Modelling and Control Using Neural Networks". Department of Chemical Engineering, University of Pennsylvania 1995.
- 22) Willis M. J., G. A. Montague, C. Di Massimo, M. T. Tham and A. J. Morris. "Artificial Neural Networks in Process Estimation And Control". Automatica. 28 (1992).

APENDICES

A.1.- APENDICE A (Métodos de Entrenamiento)

La principal forma en que se clasifican estos métodos esta hecha en base a su forma de aprendizaje, supervisado y no-supervisado.

En el aprendizaje supervisado hay un “maestro” que en la fase de entrenamiento, le “dice” a la red que tan bien sé esta comportando (aprendizaje reforzado) o cual es el comportamiento correcto que debe seguir (aprendizaje totalmente supervisado).

En el aprendizaje no supervisado la red es autónoma, tan solo “observa” los datos que se le presentan, encuentra algunas de las propiedades del conjunto de datos y aprende a reflejar esas propiedades en sus resultados.

¿Qué son exactamente estas propiedades que la red puede aprender a reconocer? Dependen del modelo de red en particular y del método de aprendizaje. Usualmente la red aprende algunas representaciones comprimidas de los datos.

Muchos de estos métodos de aprendizaje están fuertemente ligados a cierta topología (clase) de red.

A continuación se presenta una lista de estos métodos de aprendizaje.

1. APRENDIZAJE NO-SUPERVIZADO (esto es, sin maestro)

1). Redes de Alimentación Hacia Atrás:

- a). Additive Grossberg (AG)
 - b). Shunting Grossberg (SG)
 - c). Binary Adaptive Resonance Theory (ART1)
 - d). Analog Adaptive Resonance Theory (ART2, ART2a)
-

- e). Discrete Hopfield (DH)
- f). Continuous Hopfield (CH)
- g). Discrete Bidirectional Associative Memory (BAM)
- h). Temporal Associative Memory (TAM)
- i). Adaptive Bidirectional Associative Memory (ABAM)
- j). Kohonen Self-organizing Map/Topology-preserving map (SOM/TPM)
- k). Competitive learning

2). Redes Unicamente de Alimentación Hacia Adelante:

- a). Learning Matrix (LM)
- b). Driver-Reinforcement Learning (DR)
- c). Linear Associative Memory (LAM)
- d). Optimal Linear Associative Memory (OLAM)
- e). Sparse Distributed Associative Memory (SDM)
- f). Fuzzy Associative Memory (FAM)
- g). Counterpropagation (CPN)

2. APRENDIZAJE SUPERVISADO:

1). Redes de Alimentación Hacia Atrás:

- a). Brain-State-in-a-Box (BSB)
- b). Fuzzy Congitive Map (FCM)
- c). Boltzmann Machine (BM)
- d). Mean Field Annealing (MFT)
- e). Recurrent Cascade Correlation (RCC)
- f). Backpropagation through time (BPTT)
- g). Real-time recurrent learning (RTRL)
- h). Recurrent Extended Kalman Filter (EKF)

2). Redes Unicamente de Alimentación Hacia Adelante:

- a). Perceptron

- b). Adaline, Madaline
- c). Backpropagation (BP)
- d). Cauchy Machine (CM)
- e). Adaptive Heuristic Critic (AHC)
- f). Time Delay Neural Network (TDNN)
- g). Associative Reward Penalty (ARP)
- h). Avalanche Matched Filter (AMF)
- i). Backpercolation (Perc)
- j). Artmap
- k). Adaptive Logic Network (ALN)
- l). Cascade Correlation (CasCor)
- m). Extended Kalman Filter(EKF)
- n). Learning Vector Quantization (LVQ)
- o). Probabilistic Neural Network (PNN)
- p). General Regression Neural Network (GRNN)

A.2.- APENDICE B (VENTAJAS Y DESVENTAJAS DE LAS REDES NEURONALES)

Si bien es cierto que las redes neuronales tienen muchas ventajas, también es cierto que no son la panacea. Desgraciadamente, cuando se leen los artículos publicados acerca del uso de redes neuronales, los autores tienden a enfatizar las ventajas y a restarle importancia a las limitaciones y problemas asociados a estas.

Por esto antes de iniciar un proyecto de redes neuronales, es recomendable conocer las ventajas y desventajas de las mismas.

Ventajas de las redes neuronales:

1.-Comportamiento adaptivo.- Las redes neuronales tienen la habilidad de adaptarse, o aprender en respuesta a su ambiente. Aprenden mediante técnicas de entrenamiento en las cuales se alimentan a la red patrones de entrada-salida, y esta se ajusta a sí misma para minimizar el error.

2.-Propiedades de reconocimiento de patrones.- Las redes neuronales se desempeñan muy bien en el área de reconocimiento de patrones multivariable. En Ingeniería Química, el control de procesos y el diagnóstico de fallas implican una gran cantidad de reconocimiento de patrones. Por lo que no es de sorprender que estas áreas sean las que han recibido mayor atención

3.-Capacidad de filtrado, baja sensibilidad a la información incompleta o ruidosa.- Quizá sea erróneo decir que las redes neuronales son insensibles a la información incompleta o ruidosa. Sin embargo comparadas con los modelos empíricos de ajuste de curvas, estas tienen una sensibilidad menor, ya que cada nodo representa una microfunción del problema.

4.-Abstracción automática.- Las redes neuronales pueden determinar automáticamente las relaciones causa-efecto, a partir del entrenamiento con datos numéricos (a menudo imprecisos).

5.-Potencial para su uso en línea.- Si bien requieren de un largo periodo de entrenamiento, una vez entrenadas pueden calcular resultados muy rápidamente. Ya que a una red entrenada le puede tomar menos de un segundo calcular un resultado, tienen el potencial de ser usadas en línea en un sistema de control. Nótese sin embargo, que hasta ahora, la red neuronal debe ser entrenada fuera de línea.

Limitaciones de las redes neuronales.

1.-Grandes periodos de tiempo de entrenamiento.- El entrenamiento puede tomar tanto tiempo que puede hacer poco práctico el empleo de una red neuronal. Los problemas más simples pueden requerir al menos 1000 iteraciones para el entrenamiento de la red, mientras que los problemas complejos pueden requerir más de 75000. Lo que se traduce en grandes cantidades de tiempo.

2.-Grandes cantidades de datos de entrenamiento.- Si existen pocos datos de entrada-salida de un problema o proceso se debe reconsiderar el uso de redes neuronales, ya que estas se sustentan básicamente en estos datos. En consecuencia las redes neuronales son mejores para problemas en donde se cuente con una gran cantidad de datos históricos, o aquellos que nos permitan el entrenamiento con ayuda de un simulador.

3.-No se garantizan resultados óptimos.- La propagación hacia atrás es una forma creativa de poner apunto a la red, pero no garantiza que la red opere

apropiadamente. El entrenamiento puede hacer que la red trabaje adecuadamente en ciertas zonas de operación, pero no así en otras.

Problemas operacionales asociados al uso de redes neuronales, y que ocasionan un pobre desempeño de estas.

- 1.-Entrenamiento deficiente (pocos datos en el conjunto de entrenamiento)
- 2.-Fallas en los sensores lo que ocasiona la corrupción de los datos de entrada.
- 3.-Regiones de operación no previstas en el conjunto datos de entrenamiento.
- 4.- Empleo de un conjunto de datos de entrenamiento obtenido a partir de una simulación o de un proceso similar, pero no idéntico.